

# 目 录

## 第一篇 理论与方法

第一章 绪 论 .....	( 1 )
1.1 控制理论的发展与面临的挑战 .....	( 1 )
1.2 神经网络技术的发展与现状 .....	( 3 )
1.3 神经网络与系统建模和控制 .....	( 5 )
1.3.1 神经网络建模 .....	( 6 )
1.3.2 神经网络控制 .....	( 8 )
1.3.3 当前神经网络控制的研究课题 .....	( 12 )
1.3.4 神经网络与模糊控制的结合 .....	( 13 )
1.4 电液伺服控制技术的发展与现状 .....	( 14 )
1.5 本书的内容及章节安排 .....	( 16 )
第二章 神经网络控制技术基础 .....	( 18 )
2.1 控制用神经元模型 .....	( 18 )
2.2 神经网络模型及其学习算法 .....	( 20 )
2.2.1 MFNN 模型与 BP 算法 .....	( 20 )
2.2.2 DRNN 模型与动态 BP 算法 .....	( 22 )
2.2.3 复合输入 DRNN 模型及其训练 .....	( 24 )
2.2.4 CMAC 网络模型 .....	( 25 )
2.2.5 B 样条神经网络模型 .....	( 27 )
2.3 神经网络的逼近能力分析 .....	( 29 )
2.4 神经网络的训练与 BP 算法存在的缺陷 .....	( 31 )
2.4.1 神经网络的训练 .....	( 31 )
2.4.2 BP 算法存在的缺陷 .....	( 33 )
2.5 增广 LPIDBP 学习算法 .....	( 34 )
2.5.1 LPIDBP 学习算法的推导 .....	( 34 )
2.5.2 仿真研究 .....	( 37 )
2.6 全局寻优自适应快速 BP 学习算法 .....	( 39 )
2.6.1 GCAQBP 学习算法的推导 .....	( 39 )
2.6.2 GCAQBP 学习算法性能分析 .....	( 41 )
2.7 本章小结 .....	( 42 )
第三章 非线性系统的神经网络辨识 .....	( 44 )
3.1 系统辨识的基本概念 .....	( 44 )
3.2 非线性系统神经网络辨识的可行性 .....	( 45 )
3.2.1 非线性系统辨识模型 .....	( 45 )

3.2.2 非线性系统辨识模型的神经网络实现 .....	( 45 )
3.3 非线性系统的神经网络辨识方法 .....	( 48 )
3.3.1 概述 .....	( 48 )
3.3.2 非线性静态系统的神经网络辨识 .....	( 50 )
3.3.3 非线性动态系统的神经网络辨识 .....	( 54 )
3.4 神经网络在线自适应跟踪辨识 .....	( 58 )
3.4.1 辨识结构及方法 .....	( 58 )
3.4.2 电液伺服系统仿真研究 .....	( 60 )
3.5 本章小结 .....	( 62 )
<b>第四章 神经网络并行自学习鲁棒自适应跟踪控制 .....</b>	<b>( 63 )</b>
4.1 引言 .....	( 63 )
4.2 跟踪控制问题描述 .....	( 64 )
4.3 神经网络并行自学习鲁棒自适应跟踪控制器设计 .....	( 64 )
4.3.1 控制器结构及工作原理 .....	( 64 )
4.3.2 自适应神经网络模型 (ANNM) 及其训练 .....	( 66 )
4.3.3 神经网络控制器 (NNC) 及其训练 .....	( 68 )
4.3.4 运行监控器 .....	( 70 )
4.3.5 鲁棒控制器 (RC) .....	( 70 )
4.3.6 NNPSLRATC 的算法实现及其特点 .....	( 71 )
4.4 神经网络并行自学习鲁棒自适应控制系统的稳定性 .....	( 73 )
4.4.1 并行自学习系统的反馈稳定性 .....	( 73 )
4.4.2 鲁棒自适应跟踪系统的稳定性 .....	( 74 )
4.5 仿真研究 .....	( 76 )
4.5.1 控制对象 .....	( 76 )
4.5.2 仿真结果 .....	( 77 )
4.6 实验研究 .....	( 79 )
4.6.1 控制对象 .....	( 79 )
4.6.2 控制结果 .....	( 81 )
4.7 本章小结 .....	( 82 )
<b>第五章 模型参考神经网络直接自适应控制 .....</b>	<b>( 83 )</b>
5.1 引言 .....	( 83 )
5.2 广义 PID 神经网络直接自适应控制器设计 .....	( 85 )
5.2.1 控制器结构及控制算法 .....	( 85 )
5.2.2 仿真研究 .....	( 88 )
5.3 模型参考混合神经网络直接自适应控制器设计 .....	( 92 )
5.3.1 控制器结构及控制算法 .....	( 92 )
5.3.2 仿真研究 .....	( 95 )
5.4 本章小结 .....	( 96 )

<b>第六章 神经网络在线自学习模糊自适应控制 .....</b>	<b>( 98 )</b>
6.1 引言.....	( 98 )
6.2 神经网络在线自学习模糊自适应控制器设计.....	( 99 )
6.2.1 控制器结构及工作原理 .....	( 99 )
6.2.2 神经网络控制器 (NNC) 及其训练.....	( 99 )
6.3 神经网络控制系统的能控性和稳定性分析.....	( 103 )
6.4 实验研究.....	( 105 )
6.4.1 控制对象及控制系统设计 .....	( 105 )
6.4.2 实验结果 .....	( 106 )
6.5 本章小结.....	( 107 )
<b>第七章 基于神经网络辨识模型的在线迭代学习控制 .....</b>	<b>( 109 )</b>
7.1 引言.....	( 109 )
7.2 基于神经网络辨识的模型参考递推控制原理.....	( 110 )
7.3 神经网络在线迭代学习控制算法.....	( 113 )
7.3.1 迭代学习控制原理 .....	( 113 )
7.3.2 神经网络在线迭代学习控制算法及收敛性分析 .....	( 114 )
7.4 仿真研究.....	( 116 )
7.5 本章小结.....	( 121 )

## 第二篇 应用与实现

<b>第八章 电液伺服板簧试验系统的神经网络自适应控制 .....</b>	<b>( 122 )</b>
8.1 引言.....	( 122 )
8.2 电液伺服板簧试验系统的数学描述.....	( 123 )
8.3 基于范数空间的稳定性分析.....	( 125 )
8.3.1 基本理论 .....	( 126 )
8.3.2 位置闭环系统稳定性分析 .....	( 128 )
8.3.3 力闭环系统稳定性分析 .....	( 131 )
8.4 电液伺服板簧试验系统特性研究.....	( 133 )
8.4.1 静态特性试验 .....	( 133 )
8.4.2 位置控制特性试验 .....	( 134 )
8.4.3 力控制特性试验.....	( 136 )
8.5 神经网络自适应控制试验研究.....	( 137 )
8.5.1 位置伺服系统的神经网络控制 .....	( 137 )
8.5.2 力伺服系统的神经网络控制 .....	( 140 )
8.6 本章小结.....	( 143 )
<b>第九章 不对称缸电液伺服系统神经网络补偿非线性控制 .....</b>	<b>( 144 )</b>
9.1 引言.....	( 144 )
9.2 基本理论.....	( 145 )
9.3 非线性系统反馈线性化设计.....	( 147 )

9.3.1	一般方法 .....	( 147 )
9.3.2	非线性系统反馈线性化控制 .....	( 149 )
9.4	不对称缸电液伺服系统反馈线性化跟踪控制 .....	( 150 )
9.4.1	系统分析与设计 .....	( 150 )
9.4.2	仿真研究 .....	( 152 )
9.5	神经网络参数在线自适应补偿控制 .....	( 156 )
9.5.1	电液伺服系统不确定参数神经网络在线补偿方法 .....	( 156 )
9.5.2	仿真结果 .....	( 158 )
9.6	本章小结 .....	( 159 )
<b>第十章</b>	<b>液压系统压力脉动神经网络自适应主动控制 .....</b>	<b>( 160 )</b>
10.1	引言 .....	( 160 )
10.2	液压系统压力脉动主动控制原理 .....	( 161 )
10.2.1	脉动波相消性干涉的原理和实现条件 .....	( 161 )
10.2.2	液压系统压力脉动主动控制原理 .....	( 162 )
10.3	自适应压力脉动主动控制系统模型 .....	( 164 )
10.4	基于 B 样条神经网络的自适应压力脉动主动控制系统 .....	( 166 )
10.5	液压系统压力脉动主动控制仿真研究 .....	( 168 )
10.5.1	仿真系统设计 .....	( 168 )
10.5.2	主通通模型为线性模型的仿真结果 .....	( 169 )
10.5.3	主通道模型为非线性模型的仿真结果 .....	( 170 )
10.6	试验研究 .....	( 172 )
10.6.1	试验装置简介 .....	( 172 )
10.6.2	试验结果及分析 .....	( 173 )
10.7	本章小结 .....	( 175 )
<b>第十一章</b>	<b>大型智能电液伺服结构试验系统 .....</b>	<b>( 176 )</b>
11.1	工程背景 .....	( 176 )
11.2	大型结构试验系统概述 .....	( 177 )
11.3	电液伺服结构试验系统的研究现状与发展要求 .....	( 179 )
11.4	大型智能电液伺服结构试验系统设计 .....	( 180 )
11.4.1	神经网络智能伺服加载控制系统 .....	( 180 )
11.4.2	数据采集与分析系统 .....	( 184 )
11.4.3	电液执行机构 .....	( 187 )
11.4.4	主要技术指标 .....	( 189 )
11.5	实验研究 .....	( 189 )
11.5.1	静力与协调加载试验 .....	( 189 )
11.5.2	疲劳加载试验 .....	( 191 )
11.6	应用实例 .....	( 194 )
11.6.1	试验对象及要求 .....	( 194 )
11.6.2	加载及测试系统设计 .....	( 195 )

11.6.3 加载控制结果 .....	( 197 )
11.7 本章小结 .....	( 199 )
<b>第十二章 结束语 .....</b>	<b>( 200 )</b>
12.1 一般性结论 .....	( 200 )
12.2 未来的研究课题 .....	( 202 )
<b>参考文献 .....</b>	<b>( 205 )</b>

# 第一篇 理论与方法

## 第一章 绪 论

### 1.1 控制理论的发展与面临的挑战

控制理论与相对论、量子理论一起被认为是 20 世纪上半叶科学发展的三大飞跃,它是应社会发展的需要,在解决重大工程技术问题以及军事问题的实践中产生和发展起来的一门新兴学科,同时又受到人类社会已有的技术手段和知识水平的制约。经过几十年的发展,控制理论的应用和影响已经深入到社会生活的各个方面,使人类大大突破了自身能力的限制。在当今社会,可以说没有控制系统,就没有生产制造,就没有宇宙飞船甚至现代化的家用电器——简言之,就没有技术。控制系统就是使机器按期望目标运转的系统,一般需要通过反馈来进行行为调整 and 性能修正,因而也可以说,反馈的思想是控制理论的基石<sup>[1]</sup>。

控制理论的发展大体上经历了经典控制理论、现代控制理论以及 20 世纪 70 年代后期提出和发展起来的非线性智能控制理论三个发展阶段。从时间上看,非线性智能控制理论体系的形成虽然较晚,但是个别思想和概念的提出却很早就有了。经典控制理论主要处理单变量常系数线性系统的控制问题,其典型特征是用传递函数来描述系统,在频域内进行分析和综合,完成镇定任务,采用的手段有 Routh-Hurwitz 稳定性判据、Nyquist 稳定性分析、Bode 图、稳定性裕量求解及串联、并联校正等,线性叠加原理是广泛面适用的。第二阶段是现代控制理论,更确切的说应当是多变量线性控制理论,它是对经典控制理论的精确化、数学化和理论化。现代控制理论利用状态空间建模理论,克服了经典控制理论仅能分析 SISO 系统的局限性,采用的分析手段是能控性/能观性理论、极大值原理、Lyapunov 稳定性理论、反馈镇定等。这些构成了现代控制理论的基础,并使控制由一门工程设计方法上升为一门新的科学<sup>[2]</sup>。同时,为满足从理论到应用、在高水平上解决实际工程控制问题的需要,还发展了自适应控制、辨识与估计理论、卡尔曼滤波、鲁棒控制等学科分支。

经典控制理论和现代控制理论研究的是线性时不变系统的控制问题。然而,自然界和现实生活中的所有系统其实都是非线性的。非线性是一切动力学复杂性之源,正是由于非线性的作用,才孕育出大自然的万千气象、人类社会的风云变幻和人类思维的错综差异。非线性是绝对的、全局的;线性是相对的、近似的、局部的。我们平常认为的线性系统,实际上是对非线性系统的一种理想化或近似的描述<sup>[3~6]</sup>。随着科学技术的不断发展,人们对控制系统品质的要求日益提高,对实际过程的分析日益精密,从而系统非线性特征的影响也就愈发突出了。与线性系统相比,非线性系统的显著特点是存在多平衡点、极限环、分歧与混沌等现象<sup>[7~9]</sup>,其运动行为与其初始状态、系统参数及输入量之间存在

着复杂的非线性关系,因此线性叠加原理将不再适用。

非线性是绝对的,因而为实现对系统的有效控制,就不能回避其中的非线性问题或者简单地进行线性化,而必须很好地加以处理和利用,以期改善系统的控制性能。然而,传统的理论和方法在解决这些问题时,已显得难以奏效。

应用需求是推动学科进步的最有效的手段。为解决上述问题,同时满足处理不断复杂的对象、完成不断复杂的设计、以及在不确定环境中实现对不确定过程的控制的需要,必须建立新的概念、模型,探索新的方法。非线性控制理论和智能控制理论就是在这一背景下逐步发展起来的,从而使自动控制理论进入了第三个发展阶段。

如果说古典控制理论、现代控制理论是对实际非线性系统的近似化、确定化处理后,基于平衡点附近的控制行为,那么非线性控制理论则是在考查了比线性系统更“真实地”接近实际系统的效学模型的基础上进行的控制行为,它更注重处理系统的非线性、不确定性及参数突变等特性对控制性能的影响,系统的控制律是状态变量的非线性函数。

随着工程研究的深入,控制理论所面临的问题日益复杂多变,主要表现于控制对象、控制任务及控制目标的日益复杂化,系统的数学模型难以建立,这时智能控制则体现了较大的优势。通过对人脑思维方式的研究发现,人具备高度的概括、抽象、自学习、自我解答等能力。例如人骑自行车,要用机理模型来描述这一行为难度极大,而实际上我们也不必去分析人车一体化方程及其平衡条件,只要从反复的跌倒中爬起来继续训练就能学会骑车。智能控制就是以无模型为特征的更接近于人脑思维方式的一种控制理论,它是以知识信息为基础进行学习和推理,用启发式方法来引导求解过程,是含有复杂性、不确定性和模糊性且一般不存在已知算法的非传统数学公式化过程<sup>[10~12]</sup>。智能控制设计通常以定性和定量结合的方法进行系统分析与综合,其主要优点是控制器的设计摆脱了系统模型的束缚,算法简单、鲁棒性强。采用这种智能方式可以简化设计过程,使人们从严格枯燥的数学推导中解脱出来,由必然王国向理想王国迈进。

目前,智能控制已形成多种方法,其中较具典型的有:专家控制、模糊控制和神经网络控制等<sup>[13]</sup>,并以它们为代表,经过短短一二十年的发展,给整个控制理论带来了无限生机与活力。

专家控制是一种基于知识的控制方法,它作为人工智能在控制领域的较早尝试,在解决某些复杂系统的控制问题上取得了令人满意的效果。但是这种基于知识的专家系统在知识获取、知识表达和推理方式上存在着固有的缺陷,如知识的来源主要靠专家经验、知识“瓶颈”、知识“组合爆炸”等,这使得专家控制方法在工程应用上受到限制。

模糊控制和神经网络方法在一定程度上避开了这个问题,而且它们表达信息和推理的方式更合乎人的思维特点。因而,模糊控制和神经网络控制更为许多控制领域的专家所重视。

自1965年美国加州大学自动控制专家 L. A. Zadeh 创立模糊集合理论以来,模糊理论的研究取得了许多重要的成果;特别是1974年英国的 Mamdani 首次用模糊逻辑及模糊推理成功地实现了对蒸汽机的自动控制,宣告了模糊控制历史的开始。自此,模糊逻辑控制的研究和应用得到了极大的发展<sup>[14~17]</sup>,并逐渐成为智能控制的一个重要分支。

模糊控制是利用模糊逻辑能用自然语言描述人的经验这一得天独厚的长处,将系统信息经过模糊化处理,通过模糊关系的推理合成,产生相应的模糊决策。在应用中,模糊

控制是以人对被控系统的控制经验来设计控制器的,故特别适用于那些难以建模或无法建模的被控对象。典型的模糊控制系统是由三模块结构构成的:模糊化、模糊规则合成推理和模糊判决。其核心是以自然语言表示的控制规则,易为人们所接受,且构造容易,鲁棒性强。

模糊系统设计中往往包含相当多的经验成分,这使得模糊控制系统性能的优劣在很大程度上取决于设计者的经验与实际情况的符合程度。由于经验是因人而异的,故模糊控制规则的优化是个重要问题,目前尚无一套完整的好办法来解决。以至于在一些模糊规则中,有时会产生控制的空挡。模糊控制过程是一种先对变量论域离散、量化,再实施推理、决策的过程。由于对语言变量值的分档不可能太细,从而造成模糊控制的精度较差。此外,模糊控制器对系统的一些参数不敏感,表明它具有良好的鲁棒性,但由于知识获取困难,使得模糊控制的适应能力有限。文献[17]将反向传播学习算法引入模糊逻辑系统中,从而实现了从观测的输入-输出散据中归纳出模糊规则,形成了稳定自适应模糊系统的概念,并提出了一套一般性的设计方法,使模糊系统的性能得到了明显的改善。为模糊控制在工程中的应用奠定了新的理论基础。

神经网络在控制领域受到重视主要归功于它的非线性映射能力、自学习适应能力、联想记忆能力、并行信息处理方式及其优良的容错性能<sup>[18]</sup>。这些特点值得神经网络非常适合于复杂系统的建模与控制,特别是当系统存在不确定性因素时,更体现了神经网络方法的优越性。它使模型与控制的概念更加一般化。

## 1.2 神经网络技术的发展与现状

自从 McCulloch 和 Pitts 提出 MP 神经元模型以来,神经网络的研究已有 50 多年的历史,走过了一条曲折而不平衡的发展道路,几经兴衰。如今,神经网络研究又异军突起,进入一个新的发展时期,其应用研究几乎覆盖了所有的领域。

1943 年,心理学家 McCulloch 和数学家 Pitts 合作,提出了第一个神经模型(MP)<sup>[19]</sup>,从此开创了神经科学理论研究的时代。1949 年,心理学家 Hebb 通过对大脑神经细胞学习和条件反射的观察研究,提出了改变神经元连接强度的 Hebb 规则<sup>[20]</sup>,至今仍在神经网络模型中发挥着重要作用。作为人工智能的神经网络系统的研究则是从 20 世纪 50 年代末 60 年代初开始的。1957 年, Rosenblatt 提出了感知器(Perceptron)模型,试图模拟动物和人脑的感知和学习能力,并提出了引入隐层处理元件的三层感知器的概念<sup>[21]</sup>。虽然他未能解决三层感知器的训练算法问题,但为一大类神经网络模型的研究提供了重要的方向。1960 年, Widrow 和 Hoff 提出了自适应线性元件(Adaline)模型及一种有效的学习方法 Widrow-Hoff 学习规则<sup>[22]</sup>。从而在 60 年代,掀起了神经网络研究的第一次热潮。

由于神经网络的工作方式与当时占主导地位的以顺序离散符号推理为基本特征的人工智能(AI)大相径庭,因而引起了不少人的兴趣,同时在学术上也引起了很大争议。另外,随着研究的深入,人们在应用和实现方面也遇到了一时难以解决的难题。人工智能的创始人之一 Minsky 和 Papert 潜心数年,从数学上对以感知器为代表的网络系统的功能和局限性进行了深入的研究,并于 1969 年出版了颇具影响的《Perceptron》一书<sup>[23]</sup>,得出了悲观的结论。由于 Minsky 在学术界的地位,他的这些观点使许多神经网络研究者丧



失了信心。另一方面,当时数字计算机的发展正处于鼎盛时期,基于数字计算机的人工智能得到了迅速发展并取得了显著成就。整个学术界陶醉于数字计算机的成功之中,从而掩盖了发展新型模拟计算机和人工智能技术的必要性和迫切性,使神经网络的研究走向低潮。

难能可贵的是,在此期间,仍有不少学者在极端困难的条件下致力于神经网络的研究。1969年, Grossberg 等提出了自适应共振理论(ART)<sup>[24]</sup>; 1972年 Kohonen 提出了自组织映射理论<sup>[25,26]</sup>。与此同时,神经心理学家 Anderson 提出了 BSB 模型<sup>[27]</sup>; 日本学者 Fukushima 提出了认知机(Necognitron)理论<sup>[28~30]</sup>; Werbos 提出了误差反传(BP)理论<sup>[31]</sup>, Widrow 发展了 Adaline 模型<sup>[32]</sup>; Amari 则致力于有关神经网络的数学理论的研究<sup>[33]</sup>。这些开创性的研究工作为神经网络的进一步发展奠定了理论基础。

70年代后期,研究并试图模拟视、听觉的人工智能专家发现,尽管计算机在大型复杂计算方面显示出巨大威力,但却很难“学会”人们习以为常的知识和经验。此外,工程实践中的问题变得越来越复杂而难以处理,如知识的组合爆炸、信息的模糊性、计算的非线性等。这些都迫使人们思考:智能问题是否完全可以由人工智能中的逻辑推理规则来描述?人脑的智能是否可以在机器中重现?

1982年,美国加州工学院物理学家 Hopfield 提出了 HNN 模型<sup>[34]</sup>,使神经网络的研究有了突破性进展。他通过引入“能量函数”的概念,给出了网络的稳定性判据;此外, HNN 的电子电路实现为神经计算机研究奠定了基础<sup>[35,36]</sup>,同时开拓了神经网络用于联想记忆和优化计算的新途径<sup>[37]</sup>,引起了工程技术界的普遍关注,从而掀起了神经网络研究的又一热潮。接着, Feldman 和 Ballard 提出了连接网络模型<sup>[38]</sup>,指出了传统的人工智能“计算”与生物“计算”的不同点,并给出了并行分布计算的处理原则; Hinton 和 Sejnowskii 借助统计物理学的概念和方法,提出了 Boltzmann 机神经网络模型<sup>[39,40]</sup>,并采用模拟退火技术进行网络的训练,保证了整个网络系统处于全局稳定点。

如果说 Hopfield 点燃了神经网络复兴的火种,那么 Rumelhart 和 McClelland 以及他们领导的 PDP 小组则将这燎原之火燃烧得更加耀眼夺目。他们致力于认知微观结构的探索,提出了 PDP 理论<sup>[41]</sup>,同时发展了多层网络的 BP 学习算法,不仅为解决多层网络的学习问题开辟了一条成功之路,而且客观上将神经网络的研究推向了高潮。这一时期,随着大量开拓性研究工作的深入开展,数百种网络结构、学习算法应运而生<sup>[42,43]</sup>,硬件实现的研究工作也在积极开展<sup>[18]</sup>,神经网络理论的应用研究已经渗透到各个领域,并在智能控制、模式识别、自适应滤波和信号处理、非线性优化、传感技术和机器人、生物医学工程等方面取得了令人鼓舞的进展<sup>[43~48]</sup>。这些成就加强了人们对神经网络系统的进一步认识,引起了世界许多国家的科学家、研究机构及企业界人士的关注,也促成了不同学科的科学工作者联合起来,从事神经网络理论、技术开发及应用与实现的研究。国际学术交流日趋频繁,1987年6月 IEEE 在 San Diego 召开了第一届神经网络国际会议,国际神经网络学会随之成立;1988年《神经网络》杂志创刊;1990年 IEEE 神经网络会刊问世;此外,各种学术刊物的神经网络特刊、专辑不断涌现,研究成果层出不穷。

我国的神经网络研究起步较晚,始于80年代末,主要在应用领域开展了一些基础性工作。在国际神经网络热潮的带动下,研究工作受到很大重视。1989年召开了全国第一届神经网络-信号处理会议;1990年召开了第一届神经网络学术大会。从此研究日趋热

烈,各种学术刊物和学术会议上关于神经网络及应用的文章大量涌现,研究队伍日益壮大,并逐渐在国际上占有一定的地位,1992年国际神经网络学会和IEEE联合学术会议在北京召开即为例证。

由此可见,进入90年代以来,神经网络的研究进入了一个空前高涨的时期。多数研究集中在网络结构、学习算法和实际应用三个方面<sup>[46-48]</sup>。例如对静态网络,提出了许多网络模型,如BP网络、正交函数网络、径向基函数RBF网络、样条函数网络<sup>[49]</sup>、子波函数网络<sup>[50]</sup>等模型。从应用角度看,它们各有千秋。BP网络有很强的生物背景,虽与函数逼近理论略有差异,但是其卓越的输入输出映射特性在多变量函数逼近方面具有很强的优势。BP网络是目前应用最为广泛的一种网络模型,在理论上它是一种全局网络,要求使用全局信息,由于受到算法的制约,实际上只能得到局部解。径向基函数RBF网络既有生物背景,又与函数逼近理论相吻合,同样也适应于多变量函数逼近,只要中心选择得当,即可获得最优解。当然,其中的关键和难点也正是中心点集的选取。正交多项式函数网络有比较完整的理论基础,但用于多变量函数逼近时网络神经元个数膨胀较快。样条函数网络在学习时只需要局部信息,因而在学习算法的并行性、收敛速度等方面有一定的优势,但其定义域中对子域网的划分非常复杂,因而增加了使用的难度。此外,实时控制要求网络结构简单,计算收敛快。在这一点上动态网络的优势较大。比较典型的动态网络有Hopfield网络、ART网络和动态递归网络等。动态网络虽然只是单层神经元网络,但由于其内部的反馈作用,可望用较小的网络结构来实现系统的复杂的行为,所以比较适合非线性动态系统的辨识与控制<sup>[51-54]</sup>。

应用神经网络时,人们总期望它有非常快的全局收敛特性、大范围的映射泛化能力和较少的实现代价。然而,目前神经网络的并行计算能力都是通过计算机虚拟实现的,大多数情况下仍是一种串行工作模式(相对实时控制任务)。因此,在解决上述问题方面,由于受到当前硬件发展的限制,人们仍将主要精力集中在神经网络结构和快速学习算法的研究上<sup>[55]</sup>。

尽管近几年来,神经网络理论及应用研究都取得了可喜的进展,但应看到,人们对生物神经系统的研究与了解还很不够,提出的神经网络模型,无论从结构还是规模上,都是对真实神经网络的一种简化和近似。神经网络的理论仍有许多缺陷,尚待进一步发展完善。因此,要使神经网络走出实验室,真正用于工程实践中,在诸多领域还有许多工作要做。

### 1.3 神经网络与系统建模和控制

80年代初,神经网络研究的复兴,也带来了神经网络控制研究的迅速发展。尤其是从1986年Rumelhart的突破性研究以来,在控制领域,将神经网络与传统控制技术相结合也取得了许多令人鼓舞的结果<sup>[56-65]</sup>。研究方法不断涌现,理论探索和工程应用并驾齐驱,同时也引起了人们对神经网络控制的鲁棒性和稳定性的极大关注<sup>[66-68]</sup>。在这个过程中,Hunt<sup>[56]</sup>,Narendra<sup>[59]</sup>和Kosko<sup>[58]</sup>等人在神经网络控制方面做了大量开拓性的工作。这些先驱者们的工作给神经网络控制理论的发展与应用奠定了坚实的基础,具有重要的里程碑的意义。

神经网络控制的基本思想是从仿生学的角度,模拟人脑神经系统的运作方式,使机器具有人脑那样的感知、学习和推理能力。其实维纳早在《Cybernetics》一书中,就揭示了机器和生物系统所共同遵守的信息与控制规律,为人工神经网络的应用提供了理论依据。对控制科学而言,神经网络的巨大吸引力在于<sup>[56]</sup>:

- ① 神经网络本质上是非线性系统,能够充分逼近任意复杂的非线性关系。
- ② 具有高度的自适应性和自组织性,能够学习和适应严重不确定性系统的动态特性。
- ③ 系统信息等势分布存贮在网络的各神经元及其连接权中,故有很强的鲁棒性和容错能力。
- ④ 信息的并行处理方式使得快速进行大量运算成为可能。

这些特点说明神经网络在解决高度非线性和严重不确定性系统的控制方面有巨大潜力。可以说,采用传统控制理论解决的各种实际问题,几乎都可以用神经网络控制技术来解决,而许多传统控制技术不能解决的问题也可以用神经网络方法来解决。目前,神经网络控制领域许多成功的应用事例使人们看到了智能控制时代的到来。当然,由于受到当前神经网络硬件发展的制约,大规模应用的时代尚待时日;但是,具备简单功能的神经芯片的成功研制已经使人们受到了很大的鼓舞。

### 1.3.1 神经网络建模

系统建模和辨识是控制理论的基本问题。过去几十年中,人们对线性系统的建模和辨识进行了深入的研究,总结出了一整套成熟的辨识算法,可以建立具有较高可靠性的模型。然而在现实世界中,非线性是普遍存在的,而线性模型只是对非线性对象的一种简化和近似。因此当系统非线性严重且我们期望得到高品质的控制效果时,建立性能良好的非线性模型就显得至关重要。然而,利用传统的辨识方法要做到这一点,无论是在理论研究还是在工程实践中都存在着极大的困难<sup>[2]</sup>。

相比之下,神经网络在这方面显示了明显的优越性。近年来,人们将神经网络模型引入非线性系统建模和辨识中,利用神经网络所具有的对任意非线性映射的任意逼近能力,来模拟实际系统的输入-输出关系;而利用神经网络的自学习、自适应能力,可以方便地给出工程上易于实现的学习算法,经过训练得到动态系统的正向或逆向模型<sup>[56]</sup>。

与传统非线性辨识方法不同的是,神经网络辨识不受非线性模型的限制。它依据被控系统的输入输出数据对,通过学习得到一个描述系统输入输出关系的非线性映射。给定一个输入,即可得到一个输出,而不需要知道输入和输出之间存在着怎样的数学关系。这是目前非线性系统辨识中一种引人注目的新途径。由于多层前馈神经网络具有逼近任意非线性映射的能力,因此目前在系统辨识和建模中应用最多的是多层前馈网络。Narendra 等人在其经典性文章<sup>[59]</sup>中,阐明了多层前馈网络用于非线性系统辨识的可能性,并提出了神经网络用于非线性系统辨识的一般性框架和方法,为我们进行复杂系统的神经网络建模与辨识奠定了理论基础。

从控制角度看,神经网络建模有两种情况:正向建模和逆向建模。下面给出这两种情况下神经网络建模的方法和结构。

## 1. 正向建模

正向建模是指训练神经网络来学习系统的正向动态特性,得到的模型称为系统的正向模型,其训练结构如图 1-1 所示,其中神经网络与被辨识系统具有相同的输入,二者输出的误差作为网络的训练信号。这是一个教授学习问题<sup>[56]</sup>。学习结束后,神经网络模型与实际系统具有相同输入输出映射特性。神经网络可采用多层前馈网络,也可以选用具有局部逼近能力的神经网络,如小脑模型关节控制器(CMAC)等。学习算法可采用误差反传学习算法及其各种改进形式。




图 1-1 神经网络正向建模

在控制系统中,被辨识对象通常是动态系统。如何进行动态系统的建模,一般有两种方法。一是直接利用动态递归神经网络进行建模,模型的输出作为网络的输入,这种方法称为并行建模法;二是采用 NARMAX 模型

$$y(t+1) = f(y(t), \dots, y(t-n+1); u(t), \dots, u(t-m+1)) \quad (1.1)$$

利用静态神经网络学习该模型的输入输出非线性函数  $f(\cdot)$ ,并将系统的输入输出延时量  $y(t), \dots, y(t-n+1); u(t), \dots, u(t-m+1)$  作为网络的增广输入。这时图 1-1 也称为串-并行建模法,目前这种方法比较常用。

## 2. 逆向建模

逆向建模是神经网络控制系统设计经常用到的方法。假定表示系统输入输出特性的非线性函数(1.1)式可逆,则对于  $t+1$  时刻期望的输出而言,  $t$  时刻的控制输入为

$$u(t) = f^{-1}(y(t), \dots, y(t-n+1); y_d(t+1), u(t-1), \dots, u(t-m+1)) \quad (1.2)$$

神经网络逆建模就是利用神经网络学习上式中未知非线性函数  $f^{-1}(\cdot)$ 。通常有网种方法:直接逆建模法和正-逆建模法。

直接逆建模是将系统的输出作为网络的输入,网络的输出与系统的输入进行比较,并用相应的误差来训练网络而建立系统的逆模型。其结构如图 1-2(a)所示。这种方法在系统的逆不存在时,可能会得到一个不可靠的逆模型。解决的办法是采用正-逆建模法。该方法采用了一个已知的系统的正向模型,如图 1-2(b)所示。逆模型网络与系统串联,网络的输入为系统的期望输出,训练误差采用系统的期望输出和实际输出之差,或与已知的神经网络正向模型的输出之差。这种方法使逆模型网络沿期望输出轨迹进行学习,克服了采用系统输入进行训练所带来的问题。对不可逆系统,也可以通过反向传播通道

——正向模型,得到一个具有期望特性的特殊的逆模型。当采用期望输出与神经网络正向模型的输出之差训练逆模型网络时,该方法还能有效抑制实际系统噪声的影响,具有良好的鲁棒性。缺点是神经网络正向建模误差会影响逆模型网络的辨识精度。当采用系统的期望输出和实际输出之差训练逆模型网络时,正向模型仅作为误差信息的反向传播通道,其误差一般只影响逆模型网络的收敛速度,而不影响训练精度。这种方法较前者具有更好的适应性。

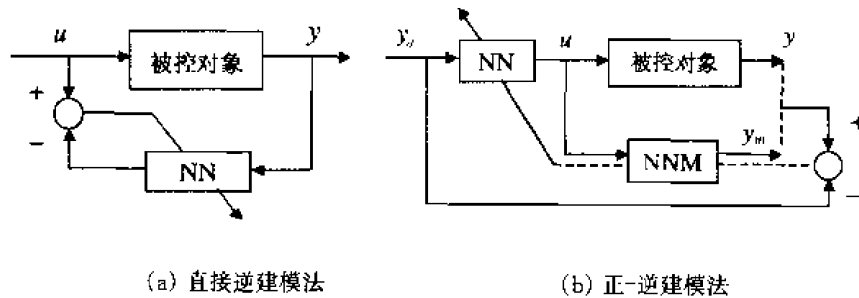


图 1-2 神经网络逆向建模

### 1.3.2 神经网络控制

神经网络应用于控制系统设计主要是针对系统的非线性、不确定性和复杂性进行的。由于神经网络的适应能力、并行处理能力和它的鲁棒性,使采用神经网络的控制系统具有更强的适应性和鲁棒性。通常神经网络在控制系统中的作用可分为如下几种:

① 充当系统的模型,构成各种控制结构,如在内模控制、模型参考自适应控制、预测控制中,充当对象的模型等<sup>[69~72]</sup>。

② 直接用作控制器<sup>[73~75]</sup>。

③ 在控制系统中起优化计算的作用<sup>[76,77]</sup>。

在神经网络控制系统中,信息处理过程通常分为自适应学习期和控制期两个阶段。在控制期,网络连接模式和权重已知且不变,各神经元根据输入信息和状态信息产生输出;在学习期,网络按一定的学习规则调整其内部连接权重,使给定的性能指标达到最优。两个阶段可以独立完成,也可以交替进行。

目前,国内外学者提出了许多面向对象的神经网络控制结构和方法<sup>[56~65]</sup>,从大类上看,较具代表性的有以下几种:

#### 1. 神经网络监督控制

监督控制是利用神经网络的非线性映射能力,使其学习人与被控对象打交道时获取的知识和经验,从而最终取代人的控制行为。它需要一个导师,以提供神经网络训练用的从人的感觉到人的决策行为的映射,导师可以是人<sup>[44]</sup>,也可以是常规控制器<sup>[64]</sup>。在此结构中,神经网络的行为有明显的学习期和控制期之分,在学习期,网络接受训练以逼近系统的逆动力学;而在控制期,神经网络根据期望输出和参考输入回忆起正确的控制输入。这类方案如图 1-3 所示。

在图 1-3(a)方案中,神经网络学习的是人工控制器的正向模型,并输出与人工控制器相似的控制作用。该方案的缺点是神经网络控制器 NNC 由于缺乏反馈,使得构成的

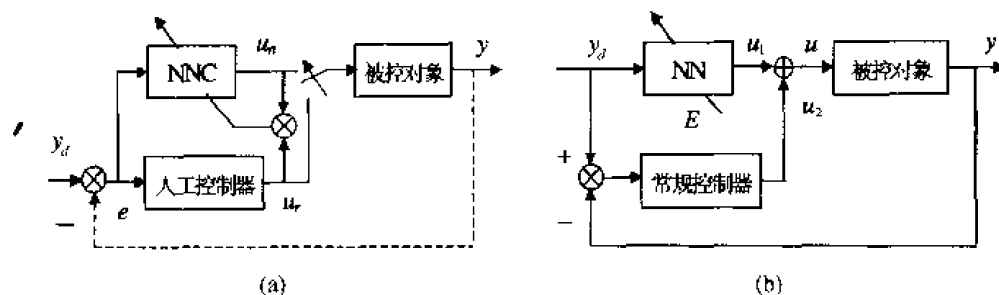


图 1-3 神经网络监督控制

控制系统的稳定性和鲁棒性得不到保证。而在图 1-3(b)方案中,神经网络实质上是一个前馈控制器,它与常规反馈控制器同时起作用,并根据反馈控制器的输出进行学习,目的是使反馈控制器的输出趋于零,从而逐步在控制中占据主导地位,最终取消反馈控制器的作用。而当系统出现干扰时,反馈控制器又重新起作用。这种监督控制方案由于在前期学习中,利用了常规控制器的控制思想,而在控制期,又能通过训练不断地学习新的系统信息,不仅具有较强的稳定性和鲁棒性,而且能有效提高系统的精度和自适应能力,应用效果较好。

## 2. 神经网络直接逆动态控制

神经网络直接逆动态控制是将系统的逆动态模型直接串联在被控对象之前,使得复合系统在期望输出和被控系统实际输出之间构成一个恒等映射关系。这时网络直接作为控制器工作,如图 1-4 所示。这种控制方案在机器人控制中得到了广泛的应用<sup>[57]</sup>。

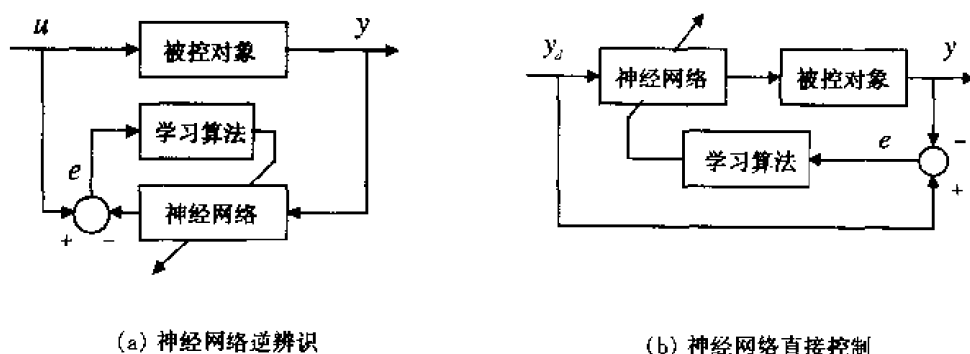


图 1-4 神经网络直接逆动态控制

直接控制方法中神经网络控制器 NNC 也相当于逆辨识器,如图 1-4(a)所示。图 1-4(b)也就是人们通常说的神经网络直接控制器的典型结构。对于周期不变的非线性系统,可以采用静态逆辨识的方式。假设系统的逆存在且可辨识,可先用大量的数据离线训练逆模型,训练好以后再嵌入控制,如文献[76]用静态神经网络进行复杂曲面加工精度的控制。离线训练逆模型问题要求网络有较好的泛化能力,即期望的被控对象的输入输出映射空间必须在训练好的神经网络输入输出映射关系的覆盖下。文献[77~80]研究了上述两种方式的实时控制情况,验证了这种方案实时控制的可行性。

但是,这种控制结构要求系统是可逆的,而被控对象的可逆性研究仍是当今一个疑难问题,这在很大程度上限制了此方法的应用。

### 3. 神经网络参数估计自适应控制

如图 1-5 所示,在这里利用神经网络的计算能力对控制器参数进行约束,优化求解。成功的范例是机器人轨迹控制<sup>[44]</sup>。控制器可以是基于 Lyapunov 的自适应控制或自校正控制以及模糊控制器。神经网络对控制器中用到的系统参数进行实时辨识和优化,以便为控制器提供正确的估计值。




图 1-5 神经网络参数估计自适应控制

### 4. 神经网络模型参考自适应控制

基于神经网络的非线性系统模型参考控制方案最早是由 Narendra 等人<sup>[59]</sup>提出的,它分为直接和间接两种,如图 1-6 所示。

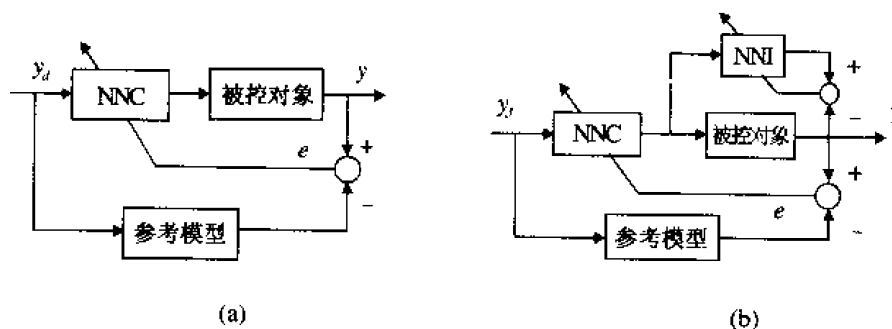


图 1-6 神经网络模型参考自适应控制

该方案将神经网络直接作为控制器,用系统输出误差来进行训练。这里,闭环系统的期望行为由一个稳定的参考模型给出,控制系统的作用是使得系统输出渐进地与参考模型的输出相匹配。这与上面介绍的直接逆动态模型的训练过程相似,当参考模型为恒等映射时,两种方法是一致的。

对于直接模型参考自适应控制,如图 1-6(a)所示,对象必须已知时,才可进行误差的反向传播,这给 NNC 的训练带来了困难<sup>[71]</sup>。为解决这一问题,可引入神经网络辨识器 NNI,建立被控对象的正向模型,构成图 1-6(b)所示的间接模型参考自适应控制。在这种结构中,系统误差可通过 NNI 反向传播至 NNC<sup>[81]</sup>。当用自适应控制器代替 NNC 时,这种方法与神经网络参数估计自适应控制类似。

## 5. 神经网络内模控制

内模控制是近年来人们熟知的一种过程控制方法,它主要利用被控对象的模型和模型的逆构成控制系统。内模控制的主要特点有:

① 假设被控对象和控制器是输入输出稳定的,且模型是对象的完备表示,则闭环系统是输入输出稳定的。

② 假设描述对象模型的算子的逆存在,且用这个逆作控制器,构成的闭环系统是输入输出稳定的,则控制是完备的,即总有  $y(k) = y_d(k)$ 。

③ 假设稳定状态模型算子的逆存在,稳定状态控制器的算子与之相等,且用此控制器时闭环系统是输入输出稳定的,那么对于常值输入,控制是渐进无偏差的。

内模控制为非线性反馈控制器的设计提供了一种直接法,具有较强的鲁棒性。用神经网络建立被控对象的正向模型和控制器,即构成了神经网络内模控制<sup>[61]</sup>,如图 1-7 所示。通常,在神经网络内模控制结构中,系统的正向模型与被控对象并联,两者之差用作反馈信号,该反馈信号通过前馈通道的滤波器和控制器处理后,对被控对象实施控制。引入滤波器的目的是为了获得更好的鲁棒性和跟踪响应效果。这种控制结构,对于线性系统,要求对象为开环稳定的;对于非线性系统,是否还有其他条件,目前尚在进一步探索研究之中<sup>[82]</sup>。

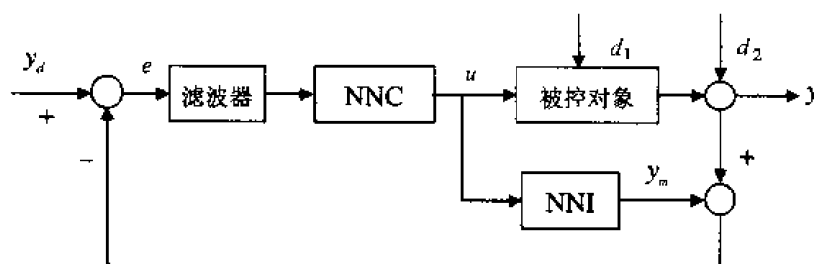


图 1-7 神经网络内模控制

## 6. 神经网络预测控制

预测控制又称为基于模型的控制,是 20 世纪 70 年代后期发展起来的一类新型计算机控制算法。这种算法的本质特征是预测模型、滚动优化和反馈校正。可以证明,这种方法对非线性系统有期望的稳定性<sup>[61]</sup>。利用神经网络建立系统的预测模型,即可构成神经网络预测控制,如图 1-8 所示。

在神经网络预测控制方案<sup>[72]</sup>中,首先由神经网络预测器建立被控对象的预测模型,并可在线修正;然后利用预测模型,根据系统当前的输入、输出信息,预测未来的输出值;最后利用神经网络预测器给出的未来一段时间内的输出值和期望输出值,对定义的二次型性能指标进行滚动优化,产生系统未来的控制序列,并以第一个控制量对系统进行下一步的控制。

在上述方法中,除第 3 种以外,其余方法的共同特点是其内部都包含有由神经网络建立的系统模型——正向模型或逆向模型,所以可称其为基于神经网络模型的控制。这里要特别指出,神经网络作为一门技术,在实际应用中往往不是以单一的角色独立承担控制



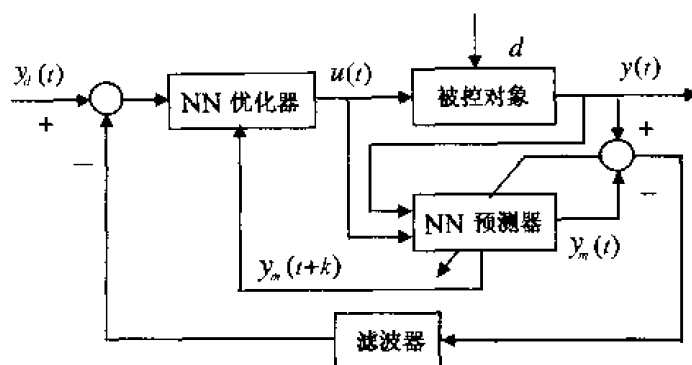


图 1-8 神经网络预测控制

任务的。对于复杂的非线性控制对象,常常是自觉或不自觉地与各种控制技术,如变结构控制、模糊控制、专家系统等相结合,构成基于神经网络的智能复合控制结构。对于实际工业过程,这类控制结构往往更具实用价值<sup>[83]</sup>。

### 1.3.3 当前神经网络控制的研究课题

从理论上讲,神经网络与传统控制理论的结合使控制系统具有相当程度的智能。利用网络的学习能力和任意非线性映射能力,通过对样本数据对的训练,神经网络可以实现对复杂系统的辨识和控制。诚然如此,目前神经网络控制的研究大多仍停留于数学仿真和实验室研究阶段,极少用于实际系统的控制。究其原因,主要在于:

- ① 存在局部极小问题,造成网络的局部收敛,影响系统的控制精度。
- ② 学习速度慢、训练时间长限制了神经网络在实时控制中的应用。
- ③ 理想的训练样本提取困难,影响了网络的训练速度和训练质量。
- ④ 网络结构不易优化,特别是隐层节点数目的选取常常带有盲目性。
- ⑤ 尚未从理论上完全解决神经网络学习算法的收敛性和神经网络控制系统的稳定性问题。

因此,与其他比较成熟的控制理论相比,当前对神经网络在控制系统方面的应用研究,应着重解决以下几个问题:

- ① 寻求可全局收敛的快速学习算法,以满足系统实时控制和良好性能的需要。
- ② 在逼近非线性函数的问题上,现有的理论只解决了存在性问题。对不同的被控对象,如何选择合适的神经网络结构,目前还缺乏理论指导。对多层前馈网络,这一问题就是网络的层数和隐层节点数的选择问题。

③ 目前神经网络控制的基本应用模式是将神经网络作为模型或控制器加入控制回路中,通过学习,实现对非线性系统的控制。如何在工程中实时实现这一控制思想,是控制专家们必须研究的课题。另外,对于这种模式,控制系统的稳定性、可控性等理论问题还需进一步研究。由于非线性系统的多样性、复杂性,加之神经网络本身的非线性,使这一问题的解决更加困难。文献[66]有比较全面的分析,但还是比较粗浅的。目前对 Hopfield 网络可以借助 Lyapunov 理论来分析<sup>[18]</sup>,而对多数网络,我们仅有收敛性分析,而且是对静态不动点进行的;对于动态轨迹跟踪系统的收敛性问题尚没有十分明朗的结果,还

须进一步研究。

④ 目前神经网络模型的使用通常采用“离线学习、在线修正”的方法,理想的训练样本获取困难。如何直接在线建立对象的模型一直是神经网络控制的一个热点问题,需要寻求一种具有良好辨识精度且可以实时应用的神经网络在线辨识方法。

⑤ 复杂系统中通常存在大量不确定性因素,神经网络要在复杂系统控制中取得成功应用,必须设法提高神经网络控制器的适应能力和控制系统的鲁棒性。

此外,神经网络硬件的研究也是实用有效的控制系统设计必须注重的问题。这是因为神经网络的大规模并行处理能力只有通过硬件才能实现。也只有这样,才能真正发挥神经网络的巨大应用潜力。

需要说明的是,神经网络控制方法中存在的有些问题,是非线性系统理论本身所固有的,并非采用神经网络模型所引起的。因此,随着非线性系统理论和其他相关科学的发展,上述问题的解决前景是乐观的。另外,虽然神经网络控制还存在理论上不完善的地方,但已在非线性系统建模和未知动态系统控制<sup>[84~86]</sup>、齿轮间隙非线性补偿<sup>[87]</sup>、主动减振<sup>[88]</sup>和结构试验<sup>[89]</sup>等许多工程实践中取得了成功的应用,可以预见,随着神经网络理论研究的进一步深入,实际应用必将在更广泛的层次上得到发展<sup>[90~95]</sup>。许多专家认为,神经网络控制研究正处于攻坚阶段,它将是通向智能控制的一条成功之路。

#### 1.3.4 神经网络与模糊控制的结合

前已述及,神经网络和模糊控制在不确定系统的控制方面,均具有巨大潜力,且各有其优缺点,能否将二者结合起来,取长补短,实现优势互补,以提高系统的性能,受到很多专家学者的关注。

神经网络和模糊系统都是无精确模型的估计器<sup>[58]</sup>,二者都是通过数值方法估计系统输入输出之间的非线性映射关系,并且在处理系统的输入输出映射关系上具有相同的网络结构<sup>[96]</sup>,只是处理的过程不同而已。神经网络是通过点-点映射来描述系统的输入输出关系的,其训练值都是确定量,因而映射关系是一一对应的,反映其输入输出关系的曲面通常比较光滑,精度较高;模糊系统的变量经过了模糊化处理,它反映的系统的输入输出映射是一种区域-区域映射,映射曲面通常为台阶状,精度较低。

模糊控制是基于专家经验和领域知识,通过被控对象的输出误差、误差变化及模糊关系的推理合成获得控制量,它以规则的方式来存储知识,运算简单,实时性好。由于使用了模糊信息,对测量噪声的抑制能力较强,因此鲁棒性较好。但控制系统的设计和品质的好坏受人为因素影响较大,如隶属函数的选取、区域的划分和规则的制定等均要依赖于专家经验。

神经网络对知识的表达并非通过规则显示的,而是隐含分布在网络结构的连接权中。控制时,通过并行分布计算即可产生正确的输出,且其权值可以通过对样本的训练获得改善,因而具有良好的自学习能力。但权值的物理意义不明确,难以对网络的收敛状态进行物理上的解释,且修正运算量大,降低了实时性。另外,预先给定的训练样本通常难以覆盖系统所有可能的情况,往往造成控制器训练不充分,影响系统的控制品质。对在线训练的控制器,控制初期的品质可能欠佳。

基于以上分析可知,上述两类系统的相似点构成了融合的基础,而它们的不同点又为

融合方式研究提供了可能。事实上,早在 20 世纪 70 年代中期,就有学者进行了神经网络与模糊控制结合的研究<sup>[97,98]</sup>。直到 1988 年,在美国国家宇航局(NASA)召开了神经网络与模糊控制结合的国际会议之后,人们才真正开始了二者结合的研究,取得了一些有益的成果<sup>[58,99,100]</sup>,并逐渐形成了一个新的研究热点。此间,最具代表性的著作要数 B. Kosko 的《Neural Networks and Fuzzy Systems: A Dynamical System Approach to Machine Intelligence》<sup>[58]</sup>。该书中,B. Kosko 通过对神经网络和模糊系统的对比研究,提出了模糊认知图(FCM)概念和模糊联想记忆(FAM)系统,研究了利用矢量量化对积空间进行聚类以获取模糊规则的方法,并将微分竞争学习(DCL)机制引入 FAM,形成自适应 FAM(AFAM),可以在输入输出样本不甚完备的情况下,获取较好的系统性能。

近年来,神经网络与模糊系统自身的研究进展推动了二者融合研究的发展。1993 年加拿大学者 W. Pedrycz 提出了模糊神经元的概念,并以此为基础提出了模糊控制器、模糊决策及模糊量表达等问题的解决方法。1994 年该国学者 M. M. Gupta 又提出了模糊神经结构,并给出了基于偏差和输出的学习方法。1995 年我国学者盛万兴也提出了模糊混合网络的拓扑结构<sup>[96]</sup>,并研究了电液伺服系统的模糊控制优化设计方法。在神经网络与模糊控制的结合研究方面,内容已涉及融合网络构造、学习算法及应用研究等方面。文献[101]提出了基于 BP 算法的模糊神经网络辨识模糊系统模型的方法,针对三种类型的模糊规则模型,提出了三种有效的模糊神经网络辨识结构;文献[102]提出了一种基于神经网络的模糊逻辑控制、决策/诊断系统;文献[103]利用 BP 算法进行模糊神经网络的自学习,实现了时间序列预测和系统辨识,并形成了模糊控制器;文献[104]提出一种基于 BP 网络的模糊控制方法,将模糊控制的经验规则以样本方式输入 BP 网络,并通过训练记忆到网络中。文献[105]提出一种基于近似推理的智能控制结构,采用动态增列式学习方法,实现模糊控制器的学习和整定。可以看出,模糊神经网络控制主要有两个方向:一是利用神经网络实现模糊控制规则;二是用模糊控制规则来描述神经网络的权系数。

目前,在模糊神经网络控制技术中,较多采用的仍是梯度算法或 BP 算法,控制的关键问题仍是权系数的优化问题。如果算法速度上不去,那么模糊神经网络控制在实时控制中的意义就会荡然无存。这是因为一种好的技术,不在于它的描述是否美妙,而在于它的客观应用效果。实用可行的方法和技术应是神经网络与模糊控制结合研究必须重视的问题。

## 1.4 电液伺服控制技术的发展与现状

电液伺服控制技术最先产生于美国的 MIT,后因其响应快、精度高很快在工业界得到了普及。电液伺服系统是以液压力元件作为执行机构,根据负反馈原理,使系统的输出跟踪给定信号的控制系统。它不仅能自动、准确、快速地复现输入信号的变化规律,而且可对输入量进行变换与放大。作为控制领域的一个重要研究对象,电液伺服系统的设计理论和方法一直受到控制学科的指导和启发,经历了从线性到非线性智能控制的发展历程。

自从 20 世纪 50 年代麻省理工学院开始研究电液伺服系统的控制至以后的几十年中,电液伺服控制设计基本上采用基于工作点附近的增量线性化模型对系统进行综合与

分析。PID 控制也因其控制律简单和易于理解,受到工程界的普遍欢迎。然而随着人们对控制品质要求的提高,电液伺服系统中 PID 控制的地位发生了动摇。这主要是由电液伺服系统的特性所决定的<sup>[107,108]</sup>。首先电液伺服系统是一严重不确定非线性系统,环境和任务复杂,普遍存在参数变化、外干扰和交叉耦合干扰;其次电液伺服系统对频带和跟踪精度都有很高的要求,如航空航天领域的系统频宽可达 100Hz,已接近甚至超过液压力机构的固有频率;另外,在高精度快速跟踪条件下,电液系统中的非线性作用已不容忽视。因此,这是一类典型的未知不确定非线性系统。这类系统扰动大,工作范围宽,时变参量多,难以精确建模。这些特点对系统的稳定性、动态特性和精度将产生严重的影响,特别是控制精度受负载特性的影响而难以预测。例如,在材料试验机上,一般的动态加载多采用 PID 方式,对不同的试件,必须更改不同的 PID 参数,尤其是在材料变形的塑性区域<sup>[109]</sup>,PID 控制难以满足人们日益精细的控制要求。再比如,在板簧动态加载系统中,板簧刚度是动态变化的,PID 控制的鲁棒性和自适应能力受到挑战。在这种情况下,仅采用传统的液压控制技术已难以满足上述应用场合的要求,机、电、液一体化技术正是在这种背景下产生的。

70 年代末至 80 年代初,计算机技术的发展为电子技术和液压技术的结合奠定了基础。随后计算机控制在电液伺服系统中得到应用,使复杂控制策略的实现成为可能。自适应控制<sup>[110,111]</sup>的引入在一定程度上提高了系统的鲁棒性和控制精度,并在解决许多工程问题上发挥了积极的作用<sup>[112~116]</sup>。文献<sup>[117,118]</sup>采用这种方法,开展了板簧电液伺服系统的自适应控制研究,取得了良好的效果。但在大扰动下,或系统存在严重不确定性时,自适应算法将趋向复杂,造成实现上的困难。此外,对非线性因素的处理能力还不尽人意<sup>[119]</sup>。

近年来,控制学科的发展推动了电液伺服系统智能控制的研究<sup>[120~123]</sup>。文献<sup>[124]</sup>研究了电液伺服系统自适应恒力加载和神经网络恒力加载系统,这也是国内电液伺服神经网络控制技术的较早应用。对非对称缸系统,国内早期在 WE 试验机上有过研究<sup>[109]</sup>;国外也进行了非对称缸系统建模和 Robust 控制的研究<sup>[125,126]</sup>,如使用双函数边界法,将阀口流量、缸体运动的非线性由线性不确定方程来描述,将非线性问题转化为参数摄动问题进行处理。文献<sup>[127,128]</sup>则研究了不对称缸的  $H_2$  鲁棒控制和自校正控制。精确反馈线性化是一种很好的非线性控制方法,近年来在电液伺服系统也展开了应用研究。文献<sup>[129,130]</sup>针对对称缸电液伺服系统阀口流量的非线性影响,研究了精确反馈线性化控制策略,取得了一些有益的结论。此外,模糊控制、变结构控制、迭代学习控制等非线性控制技术也都在电液伺服系统中取得了一席之地<sup>[131~134]</sup>。尤其是在模糊控制方面,在国家自然科学基金和横向协作课题经费的资助下,经过多年的研究和实践,已由最初的技术应用研究,逐步形成了系统化的模糊控制设计理论和方法,并在电液速度伺服系统中取得成功的应用<sup>[135]</sup>。文献<sup>[136]</sup>针对电液伺服结构试验系统的复杂特性,设计了基于模糊控制表的自适应模糊控制器,较好地解决了系统的动态跟踪问题,控制精度也得到明显改善;文献<sup>[137]</sup>将神经网络引入变结构控制中,利用神经网络辨识切换函数的实际偏差,也较好地实现了一些经典加载波形的再现。

由此可见,电液伺服系统非线性智能控制研究的前景是十分广阔的。目前存在的问题是,缺乏应用方面的非线性系统理论,对诸如控制策略设计、稳定性分析以及非线性和

智能控制理论方法在实际应用中存在的局限性进行有针对性的研究。另外,值得指出的是,虽然电液伺服系统中的非线性因素,如温度、黏度、死区、库仑摩擦等会对控制系统的设计产生一定的影响,但是这些非线性因素的影响在多数条件下远不如负载干扰的影响大,而且对死区、库仑摩擦的分析和处理,目前已有比较成熟的处理方法和结果,如相平面法、描述函数法等。在控制器的鲁棒作用下,这些影响可以在一定程度上得到削弱。另外,电液伺服系统的空载特性与负载特性差别很大,因此在进行电液伺服系统的结构设计和控制器设计时,必须考虑负载特性的影响。以往人们多停留在对线性弹簧质量负载的研究和分析中,而对非线性负载,较少有从整个非线性闭环系统的角度进行分析和综合的研究。有些文献即便涉及了这方面的研究,也大都针对具体问题进行的,并没有为电液伺服控制这一类系统建立较为完整和规范化的非线性设计理论和方法。

本书基于上述现状,试图通过对神经网络智能控制策略的研究,寻求一种新的具有一般性的控制方法,并探求一条可行的工程实现途径,实现对未知不确定非线性电液伺服系统的高品质控制。

## 1.5 本书的内容及章节安排

本书的研究对象是不确定非线性电液伺服系统,主要包括两类:一是对称缸非线性弹簧质量负载系统;二是不对称缸非线性弹性质量系统。研究内容是基于上述现状,针对电液伺服系统的特点和要求,以解决工程控制中的各种技术问题为目的,开展基于神经网络的智能控制理论与应用研究。重点是针对当前神经网络控制中存在的几个问题,结合电液伺服系统的控制需要,研究神经网络智能控制策略的理论及其工程实现方法,并通过具体应用实例,说明提出的理论和方法能使控制系统的性能得到明显的改善。

本书的章节安排如下:

第一章绪论,说明了本书研究的理论和工程背景,讨论了神经网络研究的历史和现状,分析了神经网络控制技术的发展情况及存在的问题,指明了研究的方向。

第二章是神经网络控制技术的研究基础。首先从控制角度描述了神经元模型,讨论了控制系统设计中常用的几种神经网络模型及其学习方法;结合 MFNN 和 Elman 网络的特点,构造了复合输入动态递归神经网络模型;分析了 BP 算法存在的缺陷;然后提出了两种新的训练算法:增广 LPIDBP 学习算法和全局寻优自适应 BP 训练算法,并通过理论分析和仿真研究,说明了算法具有良好的性能。

第三章研究了非线性系统的神经网络辨识问题。讨论了非线性系统的辨识模型及神经网络实现问题,针对网络适应能力的要求,提出了神经网络模型的在线自适应跟踪辨识方法,并通过仿真实验研究了电液伺服系统的神经网络建模和辨识。

第四章至第七章研究了 5 种不同特色的神经网络控制结构,主要反映了作者近年来的一些研究成果。

第四章针对模型未知的系统,提出一种神经网络并行自学习变鲁棒自适应跟踪控制方法,并证明了构成的闭环控制系统在其变量一致有界的意义上是全局稳定的。通过引入运行监控器,解决了神经网络控制方法通常存在的实时性差的问题,实现了对复杂系统的在线学习控制。最后结合电液力伺服加载系统和位移伺服加载系统,分别进行了仿真

和实验研究。可以看出,神经网络能跟踪学习系统的动力学,对模型未知的不确定非线性系统实施良好的控制。

第五章从古典 PID 反馈控制思想出发,提出了具有 PID 结构形式的神经网络模型,并设计了两类神经网络直接自适应控制器:广义 PID 神经网络直接自适应控制器和混合神经网络直接自适应控制器,提出了相应的学习算法,并对非线性板簧电液伺服系统进行了仿真研究。

第六章针对复杂系统神经网络控制前期品质欠佳的情况,基于反馈误差学习法,将模糊逻辑与神经网络控制相结合,设计了神经网络在线学习模糊自适应控制器,并证明了在一定条件下,这种控制器能保证闭环系统的稳定性。将这种控制器用于未知不确定非线性电液伺服结构试验系统的在线学习控制。实践证明,能满足系统平稳、快速、高精度、无超调的控制要求。且控制效果明显优于传统的模糊控制和反馈误差学习控制方法。

第七章从传递函数的角度出发,依据动态递归神经网络模型,提出了基于神经网络辨识的在线迭代学习控制策略,并从理论上分析了迭代学习控制算法的收敛性,最后通过仿真研究了该控制策略的有效性。

第八章至第十一章给出了作者近年来从事神经网络控制研究的 4 个工程应用实例。

第八章研究了对称缸非线性负载系统——电液伺服板簧试验系统的神经网络控制问题。首先基于范数空间稳定性理论,推导出一种新的系统稳定性分析方法,并对非线性板簧试验系统进行了稳定性分析;然后设计了电液伺服板簧试验神经网络控制系统,并进行了试验研究。

第九章针对非对称缸弹性质量非线性系统,进行了精确反馈线性化控制的研究。从理论上讲,为求得系统的精确解,须有精确的数学模型,而实际上,模型往往存在失配问题。如何克服模型失配时对系统产生的影响,是控制专家关注的问题。为此,本章提出了运用神经网络进行参数不确定补偿控制的思想,针对电液伺服系统油液弹性模量等不确定性因素的影响,设计了神经网络参数在线自适应补偿控制器,同时对不对称缸电液伺服系统进行了仿真研究。

第十章研究了液压系统压力脉动神经网络主动控制问题。分析了压力脉动主动控制原理,针对有源脉动控制系统存在的非线性和时变不确定性,设计了基于 B 样条神经网络的液压系统压力脉动主动控制系统,并进行了仿真和实验研究。

第十一章根据大型电液伺服结构试验系统的特点和发展要求,采用神经网络控制策略,研制了神经网络智能伺服加载控制系统,并采用多机并行工作方式和实时通讯手段,研制了计算机实时数据采集与分析系统,建立了一套功能完善、智能程度较高的大型结构试验装置,实现了结构的低周期疲劳加载控制和静力与协调加载控制,做到了结构试验控制与测试分析一体化。实验和应用研究表明,神经网络智能伺服加载控制系统适应能力强,对系统的未知特性、不确定性和非线性均有很好的处理能力,可满足不同试验规范的需要。

第十二章对本书的研究工作进行了总结,给出了一般性结论,并对今后的研究课题进行了讨论。

## 第二章 神经网络控制技术基础

对控制系统而言,神经网络的主要贡献在于提供了一种非线性静态映射,它能以任意精度逼近任意给定的非线性关系;能够学习和适应未知不确定系统的动态特性,并将其隐含存贮于网络内部的连接权中,需要时,可通过信息的前馈处理,再现系统的动态特性。这些特点不仅使得神经网络在解决高度非线性和未知不确定性系统的控制问题上显示了巨大潜力,而且在许多其他领域,如模式识别、信号处理、系统辨识和预报中,也取得了各种各样的应用<sup>[18,44]</sup>。

在神经网络的应用研究中,除了网络的逼近能力这一固有特性外,另一个关键问题就是网络的训练问题。在控制应用中,网络训练不仅要考虑算法的收敛性,还要考虑算法的实时性和在线实现问题。本章首先从控制角度描述了神经元模型,给出了本书控制系统设计中常用的几种神经网络模型及其学习算法,并结合动态递归网络(DRNN)和BP网络的特点,提出了复合输入DRNN;然后分析了BP算法存在的缺陷,提出了两种新的神经网络训练算法:增广LPIDBP学习算法和全局寻优自适应快速BP(GCAQBP)训练算法,并通过理论分析和仿真研究分别证明了这两种算法的优良性能。本章的内容是后续章节研究神经网络智能控制的基础。

### 2.1 控制用神经元模型

神经元实质上是一种信息处理单元,是构成神经网络的基本单元,目前尚无统一的描述模型。基于控制的观点,神经元的模型结构可以描述为输入处理环节、状态处理环节、输出处理环节和学习环节等四个部分,如图2-1所示。

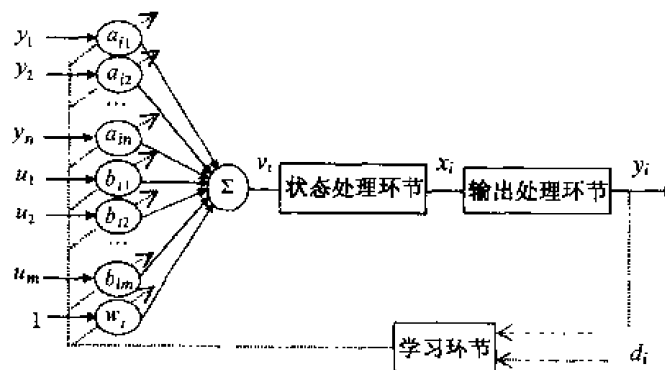


图 2-1 神经元模型结构

#### 1. 输入处理环节

输入处理环节相当于一个加权加法器,用来完成神经元输入信号的空间综合功能,即

$$v_i(t) = \sum_{j=1}^n a_{ij}y_j(t) + \sum_{k=1}^m b_{ik}u_k(t) + w_i \quad (2.1)$$

其中:  $v_i(t)$  为空间综合后的信号;  $y_j(t)$ 、 $u_k(t)$  分别为来自其他神经元的输出信号和外部输入信号;  $a_{ij}$ 、 $b_{ik}$  分别为上述信号的加权系数;  $w_i$  为一常数, 其作用是控制神经元处于某一特定状态。

## 2. 状态处理环节

输入信号对神经元状态的影响会在一段时间内持续, 状态处理环节就是用来处理神经元的内部状态信息, 对神经元的输入信号起着时间综合作用。即对某一时刻以前的输入信号进行总和和处理, 以决定该时刻神经元输出的大小。它相当于一个单输入-输出线性动态系统, 输入-输出关系为

$$X_i(s) = H_i(s)V_i(s) \quad (2.2)$$

其时域描述形式为

$$x_i(t) = \int_{-\infty}^t h(t-\tau)v_i(\tau)d\tau \quad (2.3)$$

其中  $H(s)$  和  $h(t)$  是拉氏变换对。一般地,  $H(s)$  的形式为

$$H(s) = 1/(a_0s + a_1) \quad (2.4)$$

$a_0, a_1$  的取值决定了由该神经元所构成的网络性质。如取  $a_0 = 0, a_1 = 1$  时, 构成的网络不具动态行为, 属静态网络;  $a_0 = T, a_1 = 1$  时, 网络自身有反馈连接, 这时构成的网络是动态网络, 其输入-输出关系不再是简单的映射关系, 而体现了一种动态变化过程。

## 3. 输出处理环节

输出处理环节实际上是一个非线性激活函数, 它将经过前两个环节进行时空综合后的信号, 通过一个非线性作用函数, 产生神经元的输出

$$y_i(t) = \sigma(x_i) \quad (2.5)$$

由于神经元的种类繁多, 不同神经元的输出特性各不相同, 因此神经元输出激活函数的种类也不同。一般地, 要求它满足单调、递增、连续即可, 通常可以采用如下几种非线性函数形式:

### (a) 硬限幅函数

$$\sigma(x) = \begin{cases} 0 & x \leq 0 \\ 1 & x > 0 \end{cases} \quad (2.6)$$

### (b) 线性限幅函数

$$\sigma(x) = \begin{cases} 0 & x < 0 \\ x & 0 \leq x < \beta \\ 1 & x \geq \beta \end{cases} \quad (2.7)$$

### (c) Sigmoid 函数

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.8)$$

### (d) 对称型 Sigmoid 函数



$$\sigma(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (2.9)$$

其形状分别如图 2-2 所示。




图 2-2 神经元输出激活函数的形状

#### 4. 学习环节

学习环节反应了神经元的学习特性,它对应的是某种学习规则。神经元的学习与其自身的参数和所处的状态有关。一般地,可描述为

$$\pi_i(k+1) = \pi_i(k) + \eta h(u(k), y(k), d(k), \pi_i(k)) \quad (2.10)$$

其中:  $\pi_i = \{a_{ij}, b_{ik}, w_i\}$  为神经元参数集;  $\eta$  为学习率;  $u(k)$ ,  $y(k)$  和  $d(k)$  分别是神经元的输入、输出和期望输出;  $h(\cdot)$  为学习信号。选择不同的学习信号,可得到不同的学习规则。

## 2.2 神经网络模型及其学习算法

### 2.2.1 MFNN 模型与 BP 算法

在众多的神经网络结构中,多层前馈神经网络(Multi-Layer Feedforward Neural Networks,简称 MFNN)是目前应用最广泛也是最成熟的一种网络结构。

如图 2-3 所示,一个多层前馈网络由输入层、输出层和至少一个隐层组成,各层包含一个或多个神经元,相邻两层神经元之间通过可调权值相连接,且各神经元之间没有反馈。其信息由输入层依次向隐层传递,直至输出层。每个神经元以加权和形式综合它的全部或部分输入,并根据非线性激活函数的形状产生相应的输出。网络各层神经元的输

入-输出映射关系可描述为

$$\begin{cases} y_i^l = \sigma(x_i^l) \\ x_i^l = \sum_{j=1}^{N_{l-1}} w_{ij}^l y_j^{l-1} + \theta_i^l \end{cases} \quad (l = 1, 2, \dots, L) \quad (2.11)$$

其中:  $y_i^l$  为第  $l$  层第  $i$  个节点的输出值;  $x_i^l$  为第  $l$  层第  $i$  个节点的激活值;  $w_{ij}^l$  为第  $l-1$  层第  $j$  个节点到第  $l$  层第  $i$  个节点的连接权值;  $\theta_i^l$  为第  $l$  层第  $i$  个节点的阈值;  $N_l$  表示第  $l$  层的节点数;  $L$  为总层数;  $\sigma(\cdot)$  为神经元的激活函数。(2.11)式也就是 MFNN 的信息前馈处理方程。




图 2-3 多层前馈神经网络结构

在理论研究和实际应用中,人们最常用的是具有线性输出的单隐层网络。对这种网络结构,模型(2.11)式可简化为:

$$y_i = \sum_{j=1}^H w_{ij}^2 \sigma \left( \sum_{k=1}^N w_{jk}^1 x_k + \theta_j^1 \right) + \theta_i^2 \quad (i = 1, 2, \dots, M) \quad (2.12)$$

其中:  $M$  为输出层节点数;  $H$  为隐层节点数;  $N$  为输入层节点数。

如果采用矩阵形式表示,上式可表示为:

$$Y = W_{OH}^T \sigma(W_{HI}^T X + \theta_H) + \theta_O \quad (2.13)$$

其中:  $W_{OH}$ ,  $W_{HI}$  分别是网络输出层到隐层和隐层到输入层的连接权值矩阵;  $\theta_H$ ,  $\theta_O$  分别为隐层和输出层神经元的阈值向量。在本书的后续章节中,我们常采用(2.13)式描述的三层前馈线性输出网络进行应用问题的研究,且将神经元激活函数  $\sigma(\cdot)$  取为对称型 Sigmoid 函数。

在 MFNN 中,网络权值的调整是通过著名的误差反向传播(Back Propagation,简称 BP)学习算法来进行的。因此 MFNN 通常又称为 BP 网络。

BP 算法包含正向传播和反向传播两个过程。在正向传播过程中,样本从输入层经过隐层单元层层处理,各层神经元的输出仅对下一层神经元的状态产生影响,直至输出层。若网络输出与其期望输出之间存在偏差,则进入反向传播过程。反向传播时,误差信号由原正向传播途径反向回传,并按误差函数的负梯度方向,对各层神经元的权系数进行修正,最终使期望的误差函数趋向最小。因此,BP 算法是一种以梯度法为基础的搜索算法。在算法的实现上,充分体现出了神经网络并行处理的特点。对(2.11)式所示的网络方程,BP 算法的计算公式为:

$$w_{ij}^l(k+1) = w_{ij}^l(k) - \eta \delta_i^l(k) \cdot \sigma'(x_i^l(k)) \cdot y_j^{l-1}(k) \quad (2.14)$$

其中:  $\eta$  为学习率;  $\delta_i^l(t)$  为  $l$  层第  $i$  节点的反向传播误差信号。

$$\delta_i^{l-1}(k) = \sum_{j=1}^{N_l} \delta_j^l(k) \cdot \sigma'(x_j^l(k)) \cdot w_{ji}^l(k) \quad (l = 2, \dots, L) \quad (2.15)$$

对输出层

$$\delta_i^L(k) = y_i^L(k) - y_{di}^L(k) \quad (2.16)$$

可以证明<sup>[18]</sup>, 当学习因子小于 2 时, 即能保证学习误差收敛。在使用上述规则时, 通常加入动量项, 提高算法的收敛速度。

$$w_{ij}^l(k+1) = w_{ij}^l(k) - \eta \delta_i^l(k) \cdot \sigma'(x_j^l(k)) \cdot y_j^{l-1}(k) + \alpha [w_{ij}^l(k) - w_{ij}^l(k-1)] \quad (2.17)$$

其中  $\alpha$  为动量因子, 取值范围是  $\alpha \in [0, 1)$ 。

### 2.2.2 DRNN 模型与动态 BP 算法

与一般的前馈网络不同, 动态递归神经网络 (Dynamical Recurrent Neural Networks, 简称 DRNN) 是一种将前馈网络的隐节点或输出节点上的值反馈到前一层节点上或者在本层节点上进行自反馈的网络结构。Narendra 引入线性系统传递函数矩阵的概念, 将动态递归网络与前馈网络进行了更一般化的统一描述<sup>[66]</sup>, 从而可以从线性反馈系统角度加深对动态递归网络的认识。已有研究表明, 在某些问题的研究, 如动态系统的辨识中, 较小规模的动态网络可以与大规模的前馈网络等效。

动态递归网络又分为全反馈和部分反馈两种网络形式。全反馈网络具有任意的前馈和反馈连接, 且所有连接权都可以进行修正。而在部分递归网络中, 前馈连接权可以修正, 反馈连接由一组所谓的结构单元 Context 构成, 连接权不可修正。结构单元记忆隐层的过去状态, 且在下一时刻连同网络输入一起作为隐层单元的输入, 从而使部分递归网络具有动态记忆能力。比较简单的部分动态递归网络有 Elman 网络和 Jordan 网络, 如图 2-4 所示。设 Elman 网络输出矢量为  $Y(k) \in R^m$ , 输入为  $u(k-1) \in R^r$ , 隐层单元输出矢量  $X(k) \in R^n$ , 则网络的输入输出关系可描述为

$$X(k) = F(W_{HC}X_c(k) + W_{HI}u(k-1)) \quad (2.18)$$

$$X_c(k) = X(k-1) \quad (2.19)$$

$$Y(k) = G(W_{OH}X(k)) \quad (2.20)$$

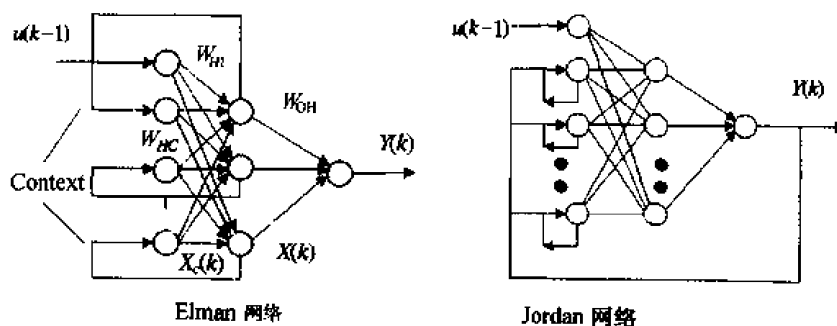


图 2-4 动态递归网络模型

其中:  $W_{HI}$  是隐层至输入层权值矩阵;  $W_{HC}$  是隐层至结构单元的权值矩阵;  $W_{OH}$  是输出层至隐层的权值矩阵。  $F$ 、 $G$  是隐层单元和输出单元激活函数组成的非线性向量函数。当  $F$ 、 $G$  取线性映射时, 可以得到如下线性状态空间表达式:

$$X(k) = W_{HC}X_c(k) + W_{HI}u(k-1)$$

$$X_c(k) = X(k-1)$$

$$Y(k) = W_{OH}X(k)$$

这里隐层单元的个数就是状态变量的个数, 即系统的阶次。

在动态递归网络中, Elman 网络结构最为简单, 运算量少, 所以非常适合实时系统辨识。对于 SISO 系统, 只有一个输入单元和一个输出单元。若考虑有  $n$  个结构单元, 则隐层的输入仅为  $n+1$  个。如果用静态 BP 网络实现同一功能, 且假定系统的状态变量个数相同, 则隐层单元的输入需要  $2n$  个。显然采用 Elman 网络时, 节点数大大减少。特别是当  $n$  较大时, 这一优点愈加突出。另外, 由于 Elman 网络的动态递归特性由内部连接提供, 网络训练时只需输入输出信号即可, 而无需状态信息。

在辨识问题中, 动态递归网络不仅可以克服一般多层前馈网络存在的网络结构及节点数膨胀和易将动态建模变成静态建模问题的缺陷, 而且难能可贵的是能够辨识系统的导数信息。

Elman 网络的权值学习可采用标准 BP 学习算法进行。但由于  $X_c(k)$  是一个动态递推过程, 而 BP 算法仅用到了一阶梯度, 因而会导致结构单元连接权的稳定性较差。为保证学习收敛, 对高阶系统, 学习率必须取得极小, 导致逼近精度很差。因此, Elman 网络只能辨识一阶线性动态系统<sup>[46]</sup>。为了克服这一缺陷, 我们可以采用动态反向传播学习算法来训练 Elman 网络, 权值调整规则可导出为<sup>[12]</sup>

$$\Delta w_{OH}^j = \eta \delta_i^o x_j(k) \quad (i = 1, 2, \dots, m; j = 1, 2, \dots, n) \quad (2.21)$$

$$\Delta w_{HI}^q = \eta \delta_j^h u_q(k-1) \quad (j = 1, 2, \dots, n; q = 1, 2, \dots, r) \quad (2.22)$$

$$\Delta w_{HC}^l = \eta \sum_{i=1}^m (\delta_i^o w_{OH}^i) \frac{\partial x_j(k)}{\partial w_{HC}^l} \quad (j = 1, 2, \dots, n; l = 1, 2, \dots, n) \quad (2.23)$$

其中

$$\frac{\partial x_j(k)}{\partial w_{HC}^l} = f_j'(\cdot) \left[ x_l(k-1) + \sum_{i=1}^n w_{HC}^{il} \frac{\partial x_i(k-1)}{\partial w_{HC}^l} \right]$$

$$\delta_i^o = (y_{di}(k) - y_i(k)) g_i'(\cdot)$$

$$\delta_j^h = \sum_{i=1}^m (\delta_i^o w_{OH}^{ij}) f_j'(\cdot)$$

当  $x_l(k-1)$  与连接权  $w_{HC}^{il}$  之间的依输关系可以忽略时, 由于

$$\frac{\partial x_j(k)}{\partial w_{HC}^l} = f_j'(\cdot) x_c^l(k) = f_j'(\cdot) x_l(k-1)$$

上述算法就退化为如下的标准 BP 学习算法

$$\Delta w_{OH}^j = \eta \delta_i^o x_j(k) \quad (i = 1, 2, \dots, m; j = 1, 2, \dots, n)$$

$$\Delta w_{HI}^q = \eta \delta_j^h u_q(k-1) \quad (j = 1, 2, \dots, n; q = 1, 2, \dots, r)$$

$$\Delta w_{HC}^l = \eta \delta_j^h x_c^l(k) \quad (j = 1, 2, \dots, n; l = 1, 2, \dots, n)$$

### 2.2.3 复合输入 DRNN 模型及其训练

为了提高 Elman 网络的动态记忆能力,有人借鉴 Jordan 网络中的自反馈方式,在 Elman 网络的结构单元中引入自反馈,构成一种改进的 Elman 网络模型<sup>[12]</sup>,如图 2-5 所示。




图 2-5 一种改进的 Elman 网络模型

加入自反馈后,结构单元的输出为

$$X_c(k) = A X_c(k-1) + X(k-1) \quad (2.24)$$

其中  $A$  为自反馈系数,是对角常数矩阵,则对第  $j$  个结构单元展开后有:

$$\begin{aligned} x_{ij}(k) &= x_j(k-1) + \alpha_j x_j(k-2) + \alpha_j^2 x_j(k-3) + \cdots \\ &= \sum_{i=1}^n \alpha_j^{i-1} x_j(k-i) \end{aligned} \quad (2.25)$$

上式表明,结构单元的输出是隐节点输出的加权和,由于系统的阶数与当前时刻以前的拍数有关,因而引入自反馈单元增加了 Elman 网络对高阶系统的逼近能力。为保证收敛,要求  $0 < \alpha_j < 1$ 。当  $\alpha_j$  接近于 1 时,表示结构单元对过去时刻的记忆加强了。经过修正后,Elman 网络的非线性方程为

$$X(k) = F(W_{HC} X_c(k) + W_{HI} u(k-1)) \quad (2.26)$$

$$X_c(k) = A X_c(k-1) + X(k-1) \quad (2.27)$$

$$Y(k) = G(W_{OH} X(k)) \quad (2.28)$$

网络权值的学习算法可以直接采用标准 BP 算法,调整规则为<sup>[12]</sup>

$$\Delta W_{OH}^i = \eta \delta_i^o x_j(k) \quad (i = 1, 2, \dots, m; j = 1, 2, \dots, n) \quad (2.29)$$

$$\Delta W_{HI}^q = \eta \delta_j^h u_q(k-1) \quad (j = 1, 2, \dots, n; q = 1, 2, \dots, r) \quad (2.30)$$

$$\Delta W_{HC}^l = \eta \sum_{i=1}^m (\delta_i^o w_{oi}^l) \frac{\partial x_j(k)}{\partial w_{HC}^l} \quad (j = 1, 2, \dots, n; l = 1, 2, \dots, n) \quad (2.31)$$

其中

$$\frac{\partial x_j(k)}{\partial w_{HC}^l} = f_j'(\cdot) \tau_l(k-1) + \alpha \frac{\partial x_j(k-1)}{\partial w_{HC}^l}$$

可以看出,权值的调整规则与基本 Elman 网络采用动态反向传播学习算法是一致的。这就表明修改的 Elman 网络采用标准 BP 算法就能达到基本 Elman 网络采用动态 BP 算法所能达到的效果,即能有效地辨识高于一阶的动态系统。

针对 SISO 系统,若取图 2-5 所示的 Elman 网络结构为  $1 \times \text{HN} \times 1$ ,其中 HN 为结构单元数也即隐层单元数目,则对应的 BP 网络的结构为  $(1 + \text{HN}) \times \text{HN} \times 1$ 。在系统辨识和控制中,BP 网络的输入常由系统的输入输出状态来构成,可利用的系统信息较多;而 Elman 网络仅有一个系统当前时刻的输入为网络输入,依靠网络对系统的逐步认识反馈产生作用,因而隐层单元的初始值对网络收敛有较大的影响。作者通过研究发现,Elman 网络的泛化能力较差,一般仅能实现对给定函数的逼近。

为了提高泛化能力,受 BP 网络结构的启发,我们在 Elman 网络的结构单元中,增加系统的部分输入输出信息,构成一种新的网络模型,称之为复合输入动态递归神经网络

(Compound Input Dynamical Recurrent Neural Networks, 简称 CIDRNN)模型,如图 2-6 所示。




图 2-6 复合输入 DRNN 模型

复合输入动态神经网络的非线性关系为：

$$X(k) = F(W_{HC}X_c(k) + W_{HI}u(k-1)) \quad (2.32)$$

$$X_c(k) = AX_c(k-1) + BX(k-1) + CZ(k-1) \quad (2.33)$$

$$Y(k) = G(W_{OH}X(k)) \quad (2.34)$$

其中： $Z(k-1) = [u(k-2), \dots, y(k-1), \dots]^T$  为系统的输入输出状态向量； $A$  为自反馈系数矩阵； $B$  为反馈系数矩阵； $C$  为前馈滤波系数矩阵。显然当  $C=0$  时，图 2-6 所示网络结构与图 2-5 相同。类似地，复合输入 DRNN 也可以用标准 BP 算法进行训练。CIDRNN 网络与 Elman 网络相比，由于利用了较多的系统资源，因此收敛速度和泛化能力有所提高；与 BP 网络相比，CIDRNN 在实时动态反馈的作用下，可望用较小的网络结构实现对高阶系统的辨识和控制。

#### 2.2.4 CMAC 网络模型

CMAC 网络是 J.S. Albus 于 1975 年最早提出来的，是小脑模型关节控制器 (Cerebella Model Arculation Controller) 的简称<sup>[138]</sup>。它是仿照小脑如何控制肢体运动的原理而建立的一种神经网络模型。因此，CMAC 最初主要用来求解机械手的关节运动。它由一个固定的非线性输入层和一个可调的线性输出层组成，结构如图 2-7 所示。W.T. Miller 等人把 CMAC 网络成功地应用到机器人控制上<sup>[139]</sup>，S. Cetinkunt 等又将其应用于高精度机械工具的伺服控制<sup>[140]</sup>。由于 CMAC 是基于局部学习的神经网络，所以学习速度快，非常适合于实时控制。

和 BP 网络一样，CMAC 也可以逼近任意的非线性关系。设待逼近的函数映射关系为

$$Y = f(X) \quad (2.35)$$

其中  $X = [x_1, x_2, \dots, x_n]^T$ ,  $Y = [y_1, y_2, \dots, y_r]^T$ 。如图 2-7 所示，CMAC 神经网络通过两个阶段映射来实现上述关系。

(1)  $S: X \rightarrow A$ , 即  $\alpha = S(X)$

这一功能由 CMAC 网络的输入层来实现。其中  $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_m]^T$  是  $m$  维相联空




图 2-7 CAMC 网络模型

间  $A$  中的向量。 $\alpha_i$  的值只取 1 或 0 两个值。对于某个特定的  $X$ , 只有其中少数元素为 1, 大部分元素为 0。可见  $\alpha = S(X)$  实现的是一个特定的非线性映射。该非线性映射在设计网络时就已经确定。输入空间中的一个点对应于  $\alpha$  中的几个元素 1, 也即对应相联空间  $A$  中的一个局部区域。

(2)  $P: A \rightarrow Y$ , 即  $Y = P(\alpha) = W\alpha$

这一功能由 CMAC 网络的输出层来实现。这是一线性映射, 其中

$$W = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1m} \\ \vdots & \vdots & \vdots & \vdots \\ w_{r1} & w_{r2} & \cdots & w_{rm} \end{bmatrix} \quad \alpha = \begin{bmatrix} \alpha_1 \\ \vdots \\ \alpha_m \end{bmatrix}$$

对于第  $i$  个输出, 则有

$$y_i = P_i(\alpha) = \sum_{j=1}^m w_{ij} \alpha_j \quad (i = 1, 2, \dots, r) \quad (2.36)$$

类似于 BP 网络的误差反向传播算法, CMAC 神经网络的连接权学习算法为

$$w_{ij}(k+1) = w_{ij}(k) + \beta(y_{di} - y_i) \alpha_j / \alpha^T \alpha \quad (2.37)$$

其向量形式为

$$w_i(k+1) = w_i(k) + \beta(y_{di} - y_i) \alpha / \alpha^T \alpha \quad (2.38)$$

其中:  $y_{di}$  和  $y_i$  分别表示第  $i$  个输出分量的期望值和实际值;  $\beta$  为学习率。可以证明: 当  $0 < \beta < 2$  时可保证该学习算法的收敛性。

令  $e_i(k) = y_{di} - y_i(k) = y_{di} - w_i(k) \alpha(x)$ , 则

$$\begin{aligned} \Delta e_i(k) &= e_i(k+1) - e_i(k) \\ &= [y_{di} - y_i(k+1)] - [y_{di} - y_i(k)] \\ &= -[y_i(k+1) - y_i(k)] \\ &= -[w_i(k+1) - w_i(k)] \alpha(x) \\ &= -\Delta w_i(k) \alpha(x) \end{aligned} \quad (2.39)$$

同时(2.38)式可写为

$$\Delta w_i(k) = \beta e_i(k) \alpha(x) / \alpha^T(x) \alpha(x) \quad (2.40)$$

将(2.40)式代入(2.39)式可得

$$\Delta e_i(k) = -\beta e_i(k) a^T(x) a(x) / a^T(x) a(x) = -\beta e_i(k) \quad (2.41)$$

即

$$e_i(k+1) = (1-\beta)e_i(k) \quad (2.42)$$

若要求迭代学习过程稳定,即  $\lim_{k \rightarrow \infty} e_i(k) = 0$ , 则根据离散系统的稳定性条件,要求  $|1-\beta| < 1$ , 即要求  $0 < \beta < 2$ 。

CMAC 网络具有如下特性:

① 可实现从输入到输出的任意映射,输入向量各分量的量化精度愈高,分块愈细,逼近任意函数的精度就愈高。

② 具有局部扩展功能,即在输入空间中靠近的向量,对应的输出也是靠近的。

③ 采用 LMS 自适应算法,可得到全局最小值。

④ 由于相联空间中只有少数几个元素为 1,其余均为 0,因此在一次训练中只有少数的连接权需要调整,计算量比 BP 网络要小。

### 2.2.5 B 样条神经网络模型

进一步考查 CMAC 神经网络,其输出函数可以理解为,对单输入情况,  $\alpha_j(x)$  ( $j=1, 2, \dots, m$ ) 可以看成一系列矩形基函数;存在两个输入时,  $\alpha_j(x)$  可看成是长方体基函数,  $w_j$  则看成是与第  $j$  个基函数相关联的权。

由于 CMAC 网络是一种类似感知器的相联记忆网络,因此,这样的基函数也称为接受域(receptive field)函数。采用这样的观点,CMAC 神经网络也可表示为如图 2-8 所示。




图 2-8 基于基函数解释的 CMAC 神经网络

由于 CMAC 神经网络的基函数形状非常简单,因而它具有实现容易、学习速度快的优点。但它的输出是用台阶形函数来逼近一个光滑函数,因而逼近精度不高<sup>[12,18]</sup>。为了提高逼近精度就必须提高分辨率,而提高分辨率带来的后果是增加了对存储容量的要求,这是一对矛盾。另外,CMAC 神经网络也不能学习所逼近函数的导数。为了克服这些缺点,人们基于样条插值的原理,设计了一种神经网络模型,其接受域函数是一样条函数,因此称为 B 样条神经网络。其结构仍如图 2-8 所示。B 样条神经网络的接受域函数通常由一些局部的多项式构成,并要求在其连接点上满足一定的连续性条件。例如上述的 CMAC 即可看成是由一阶基函数组成的最简单的 B 样条神经网络。CMAC 的基函数可看成是局部的零阶多项式。



### (1) 输入空间的分割

为了定义 B 样条神经网络的基函数,首先需要定义输入空间的分割方法。

设输入向量为  $X = [x_1, x_2, \dots, x_n]^T$ , 且  $x_i \in I_i$ ,  $I_i$  为一有限区间, 定义为

$$I_i = \{x_i : x_i^{\min} \leq x_i \leq x_i^{\max}\}$$

对该区间进行如下分割:

$$x_i^{\min} < \lambda_{i,1} \leq \lambda_{i,2} \leq \dots \leq \lambda_{i,m_i} < x_i^{\max}$$

其中称  $\lambda_{i,j}$  为第  $j$  个内节点。同样也可定义  $\lambda_{i,j}$  的外节点:

$$\dots \leq \lambda_{i,-1} \leq \lambda_{i,0} \leq x_i^{\min} \quad x_i^{\max} \leq \lambda_{i,m_i+1} \leq \lambda_{i,m_i+2} \leq \dots$$

一般情况下,所有左边的外节点均置于  $x_i^{\min}$ , 所有右边的外节点均置于  $x_i^{\max}$ 。若两节点在同一位置,则称该节点为重节点。所有节点将整个区间  $I_i$  分为如下  $m_i + 1$  个子区间  $I_{i,j} (0 \leq j \leq m_i)$

$$I_{i,j} = x_i : \begin{cases} x_i \in [\lambda_{i,j}, \lambda_{i,j+1}] & (j = 0, 1, \dots, m_i - 1) \\ x_i \in [\lambda_{i,j}, \lambda_{i,j+1}] & (j = m_i) \end{cases} \quad (2.43)$$

### (2) 基函数

首先考虑一维输入时基函数的构成,设  $N_j^k(k)$  为定义在  $\lambda_{j-kd}, \lambda_{j-kd+1}, \dots, \lambda_j$  上的  $k$  阶基函数,从而有感受域  $\alpha_j(x) = N_j^k(x)$ 。这里称为  $d$  扩展系数。若这些节点重合在一起,则  $N_j^k(x) = 0$ , 否则它用如下的递推关系进行计算

$$N_j^k(x) = \left( \frac{x - \lambda_{j-kd}}{\lambda_{j-d} - \lambda_{j-kd}} \right) N_j^{k-1}(x) + \left( \frac{\lambda_j - x}{\lambda_j - \lambda_{j-(k-1)d}} \right) N_j^{k-1}(x) \quad (2.44)$$

其中

$$N_j^1(x) = \begin{cases} 1 & x \in [\lambda_{j-d}, \lambda_j) \\ 0 & x \notin [\lambda_{j-d}, \lambda_j) \end{cases}$$

上面定义的基函数具有如下的性质:

- ① 正定性:  $N_j^k(x) > 0, x \in [\lambda_{j-kd}, \lambda_j)$ ;
- ② 紧密性:  $N_j^k(x) = 0, x \notin [\lambda_{j-kd}, \lambda_j)$ ;
- ③ 归一性:  $\frac{1}{d} \sum_j N_j^k(x) = 1, x \in I$ 。

根据上述基函数的表达式(2.44),就可以求出该基函数的各阶导数了。这一点对控制系统设计非常有用,也是 B 样条神经网络优于 CMAC 网络的一个特点。如对 SISO 结构,有

$$y = \sum_{j=1}^m w_j \alpha_j(x) = \sum_{j=1}^m w_j N_j^k(x)$$

则神经网络输出对输入的导数为

$$\frac{d^s y}{dx^s} \equiv y^{(s)} = \sum_{j=1}^m w_j^{(s)} N_j^k(x) \quad (2.45)$$

下面考虑多变量基函数的构成。

设输入向量  $X \in R^n$ , 则定义多维变量基函数为

$$\alpha_{j_1, j_2, \dots, j_n}(x) = \prod_{i=1}^n N_{i, j_i}^{k_i}(x_i)$$

其中  $N_{i, j_i}^{k_i}(x_i)$  表示  $x_i (i = 1, 2, \dots, n)$  的第  $j_i (i = 1, 2, \dots, m_i)$  个单变量基函数;  $k_i$  为  $x_i$  的基函数的阶数;  $d_i$  为扩展系数。多维变量基函数的总数为

$$m = \prod_{i=1}^n m_i$$

可见,多维变量基函数是每个坐标分量基函数可能的组合结果。

同样,多维变量基函数也满足正定性、紧密性及归一性等性质。

与 CMAC 网络类似,B 样条神经网络从输入到输出的映射也可分为以下两步:

(1)  $X \rightarrow \alpha(x)$

这是图 2-8 中输入层实现的功能,其中  $\alpha(x) = [\alpha_1(x), \alpha_2(x), \dots, \alpha_m(x)]^T$  是  $m$  维相联空间  $A$  中的向量,  $\alpha_j(x)$  表示对于给定的输入  $x$  所对应的第  $j$  个基函数的输出值。由于基函数的紧密性和正定性,  $\alpha(x)$  中只有  $\rho = \prod_{i=1}^n k_i d_i$  个元素非零,且其值在 0 与 1 之间,其余元素均为零。

可见,  $\alpha(x)$  实现的是一个非线性映射,该映射在设计网络时便已确定。网络的有关参数为  $m_i, k_i, d_i (i = 1, 2, \dots, n)$ 。

(2)  $\alpha(x) \rightarrow y, y = Wa(x)$

这一功能由输出层来实现。可见输出层是线性映射。对于第  $i$  个输出,有

$$y_i = \sum_{j=1}^m w_{ij} \alpha_j(x) \quad (i = 1, 2, \dots, r) \quad (2.46)$$

其中连接权是可以调整的参数。连接权学习可以采用与 CMAC 神经网络相同的学习算法,学习规则为

$$w_{ij}(k+1) = w_{ij}(k) + \beta[y_{di} - y_i(k)]\alpha_i/\alpha^T\alpha \quad (2.47)$$

根据前面的讨论,学习率的取值范围为  $0 < \beta < 2$ 。为使学习误差单调衰减,通常只取  $0 < \beta < 1$ 。

## 2.3 神经网络的逼近能力分析

神经网络在控制领域中取得成功的应用,主要归功于网络可实现复杂的输入-输出非线性映射关系。因此,许多学者都致力于 NN 映射能力问题的研究,并取得了许多令人满意的结论。以多层前馈网络 MFNN 为例,早在 1987 年, Wieland 和 Leighton<sup>[141]</sup>就研究指出,一个具有阈值的三层网络可以将空间划分为非凸子空间。至 1989 年, Cybenko<sup>[142]</sup>、Funahashi<sup>[143]</sup>、Hornik<sup>[144]</sup>等分别用不同的方法证明了一个共同的结论。即仅含一个隐层的前馈网络能以任意精度逼近定义在  $R^n$  中的一个紧集上的任意非线性函数。

下面为后续工作研究的需要,不加证明的给出一些学者的研究结论。

**定理 2.1**<sup>[142]</sup> 如果  $\sigma(x)$  是一个有界连续 Sigmoid 函数,则下述形式

$$\sum_{j=1}^N \alpha_j \sigma(y_j x + \theta_j) \quad (2.48)$$

的函数全体(或线性组合函数集)在  $C(I^n)$  中稠密, 即  $\forall f \in C(I^n)$  及  $\epsilon > 0$ , 有

$$\left| f(x) - \sum_{j=1}^N \alpha_j \sigma(y_j x + \theta_j) \right| < \epsilon \quad (2.49)$$

成立。其中  $y_j \in R^n$ ,  $x \in I^n$ ,  $y \cdot x$  为  $y$  与  $x$  的内积,  $\alpha_j, \theta_j$  分别为实数,  $I^n = [0, 1]^n$ , 而  $C(I^n)$  是超立方  $I^n$  中的连续函数空间。

定理 2.1 不仅给出了单隐层前馈网络的表示方法, 而且指出了采用隐单元作用函数为 Sigmoid 函数、输入-输出单元为线性函数的三层前馈网络能以任意精度逼近  $C(I^n)$  上的连续函数。定理 2.1 要求  $\sigma(x)$  是连续的, 文献[145]的工作又证明了  $\sigma(x)$  的连续性是不必要的, 起决定作用的是它的有界性。

**定理 2.2** <sup>[143]</sup> 设  $\sigma(x)$  为有界单调增连续函数,  $K$  为  $R^n$  的紧子集,  $f(x)$  为  $K$  上的实值连续函数, 那么, 对任意  $\epsilon > 0$ , 存在正整数  $N$  和实数  $C_i, \theta_i (i=1, \dots, N)$ ,  $W_{ij} (i=1, \dots, N; j=1, \dots, n)$ , 使得

$$\left| f(x) - \sum_{i=1}^N C_i \sigma\left(\sum_{j=1}^n W_{ij} x_j + \theta_i\right) \right| < \epsilon \quad (2.50)$$

对一切  $x \in R^n$  成立。

定理 2.2 指出, 一个隐层作用函数为  $\sigma(x)$ 、输入-输出层作用函数为线性函数的三层前馈网络能以任意精度逼近  $K$  上的任意连续函数。它不要求  $\sigma(x)$  一定是 Sigmoid 函数, 而仅是有界单调增或有界连续函数即可。此外, Hornik<sup>[146]</sup>等人的研究工作表明, 只要作用函数是一个非多项式的 Riemann 可积函数, 三层前馈网络就具有通用逼近性。

**定理 2.3** <sup>[147]</sup> 设  $\sigma(x): R \rightarrow R$  为有界连续函数,  $f(x)$  为定义在  $R^n$  中某紧集  $K$  上的连续函数, 那么, 对任意  $\epsilon > 0$ , 存在正整数  $N$ ,  $C_i, \theta_i \in R$  及矢量  $W_i \in R^n$  使得

$$\left| f(x) - \sum_{i=1}^N C_i \sigma(w_i x + \theta_i) \right| < \epsilon \quad (2.51)$$

对一切  $f(x) \in K$  成立。

上述定理说明的是当  $f(x)$  为连续函数时, 可用一三层前向网络逼近。那么当函数不连续时, 情况又怎样呢? 下面的定理给出了神经网络逼近非连续函数时的情形。

**定理 2.4** <sup>[148]</sup> 设神经元激活函数  $\sigma(x)$  为阈值特性, 那么  $\sum C_i \sigma(w_i \cdot x + \theta_i)$  在  $L_2(U)$  ( $U \subset R^n$  是  $n$  维单位超立方体) 中是  $\rho_2$  稠密的。即  $\forall f \in L_2(U)$  及  $\epsilon > 0$ , 有

$$\int_U \left| f(x) - \sum_{i=1}^N C_i \sigma(w_i \cdot x + \theta_i) \right|^2 dx < \epsilon \quad (2.52)$$

成立。其中  $\rho_2(f) = \left[ \int_U |f(x)|^2 dx \right]^{1/2}$ 。

由于  $f(x)$  定义在  $[-1, 1]$  上且满足平方可积条件  $\int_{-1}^1 |f(x)|^2 dx < \infty$ , 因此  $f(x)$  可以是非连续函数。定理 2.4 表示三层前向网络可以逼近非连续函数。事实上, 这一点在神经网络模式学习和分类中已得到应用。

由上述定理可以得出如下结论: 对任意给定的函数  $f(x_1, \dots, x_n)$  和误差精度  $\epsilon > 0$ , 总存在一个三层前馈神经网络, 其隐层神经元的作用函数为  $\sigma(x)$ , 输入-输出层均为线性神经元, 使得网络的输入-输出关系  $Y = NN_f(x_1, \dots, x_n)$  总能以给定的精度逼近给定的函数  $f(x_1, \dots, x_n)$ 。

上述定理虽然是针对前馈网络给出的,但研究表明其他网络亦具有类似的逼近特性。这些研究工作非常重要,为神经网络的应用提供了坚实的理论基础。但是,它们只是从存在性方面证明了网络的逼近能力。在实际应用中,还需要进一步研究网络的构造和学习问题。

## 2.4 神经网络的训练与 BP 算法存在的缺陷

### 2.4.1 神经网络的训练

前文指出,一个 MFNN 可以任意逼近一个紧集上的任意函数。这一特点是神经网络得到广泛应用的理论基础。但是,在实际应用中,目前尚未找到较好的网络构造方法,确定神经网络的结构和权值参数,来描述给定的映射或逼近一个未知的映射,只能通过学习方式来得到满足要求的网络模型。

神经网络的训练问题可描述如下:

给定一个训练样本集  $\{(X_p, Y_{dp}), X_p \in R^n, Y_{dp} \in R^m, p = 1, 2, \dots, P\}$ , 它通过输入-输出对以隐含形式定义了某种函数关系  $F: R^n \rightarrow R^m$ ,  $F$  的具体表达式形式可能是未知的。我们期望能利用 NN 所具有的任意逼近能力来表示这一未知的函数关系。即确定一个合适的模型结构并寻找一组适当的权值  $\{W^*, \theta^*\}$  构成网络  $y = NN(X, W^*, \theta^*)$ , 使得如下的误差指标函数最小:

$$E = \frac{1}{2} \sum_{p=1}^P \sum_{i=1}^{N_L} (y_i^p(t) - y_{di}^p(t))^2 \quad (2.53)$$

其中:  $y_{di}(t)$  是网络的期望输出;  $y_i(t)$  为网络的实际输出,可由(2.11)式给出;  $N_L$  为输出层的节点数;  $P$  为训练样本的数量。对某一给定的模式训练,上述误差函数则为

$$E_p = \frac{1}{2} \sum_{i=1}^{N_L} (y_i(t) - y_{di}(t))^2 \quad (2.54)$$

由此可见,在神经网络的训练中,存在三个要素:合适的样本集、合适的网络结构与参数及合适的指标函数。本书中,神经网络的学习可以理解为:对确定的网络结构,寻找一组满足要求的权值参数,使给定的指标函数最优。通常,找到最优的权值  $\{W^*, \theta^*\}$  很困难甚至是是不可能的。事实上,在实际应用中,训练样本或多或少地都会受到噪声的污染,即使侥幸得到了最优解也只能是对真实函数关系的一个近似。因此,人们通常希望得到一个满意解即可。为此给定一个逼近精度  $\epsilon > 0$ , 只要能找到一组权值  $\{W, \theta\}$  使条件  $E < \epsilon$  得到满足,则称  $y = NN(X, W, \theta)$  是对未知函数的一个逼近。这可能是一个最优点,也可能是一个满足要求的极小点。

在实际应用中,要求通过学习给定样本构造的网络  $y = NN(X, W, \theta)$  具有良好的泛化能力,即要求对训练样本集之外的某一测试集中的点  $\{(X_q, Y_{dq}), q = 1, 2, \dots, Q\}$ , 也能满足逼近精度条件  $E < \epsilon$ 。只有这样,网络在应用时才会具有良好的推广特性。神经网络的泛化能力是神经网络应用研究中一个受到普遍关心和重视的问题,其关键问题有二:一是网络结构本身是否具备泛化能力,如线性网络对于非线性问题有先天的不足;二是所给的训练数据能否概括神经网络的泛化区域内被控系统可能具有的输入输出特性。我们知道,在传统的线性系统辨识中,必须满足持续激励的条件,而用神经网络进行

非线性系统辨识时对训练数据有什么特殊的要求,至今没有理论上的解释。通常,我们要求训练样本集能充分反映出所隐含函数的真实特性,同时要求神经网络学习后能保证在样本点之间实现良好的光滑过渡。当神经网络的泛化能力严重不足时将导致网络仅对训练数据有效,而丧失其实际应用价值。

下面来讨论神经网络训练的具体步骤。

### 1. 获取训练样本集合

获取训练样本集合是训练神经网络的第一步,也是十分重要和关键的一步。它包括训练数据的收集、分析、选择和预处理等。

首先要在大量的测量数据中确定出最主要的输入模式。即对测量数据进行相关性分析,找出其中最主要的量作为输入。在确定了主要输入量后,要对其进行预处理,将数据变化到一定的范围,如 $[-1,1]$ 或 $[0,1]$ 等,并剔除野点,同时还可以检验其是否存在周期性、固定变化趋势或其他关系。对数据的预处理分析的目的是使得到的数据便于神经网络学习和训练。

通常,系统的输入输出特性包含在数据样本中。因此训练数据量的选择也是一个很关键的问题。一般来说,取的数据越多,训练结果就越能正确反映系统的输入输出关系,而太少的数据可能得不到正确的结果。但是太多的数据又会增加数据收集与分析的代价及网络训练的时间。事实上,决定数据量的大小的因素很多,如网络的大小及数据的分布等。其中网络的大小最为关键。通常是较大的网络需要较多的数据。一个经验规则是:训练模式应是连接权总数的 $5\sim 10$ 倍<sup>[12]</sup>。

### 2. 选择网络类型与结构

神经网络的类型很多,需要根据任务的性质和要求来选择合适的网络类型。如对函数估计问题,可选用BP网络。当然也可以设计一个新的网络类型,来满足特定任务的需要,但这一般比较困难。通常是从已有的网络类型中选择一种比较简单而又满足要求的网络。

网络类型确定后,就要确定网络的结构及参数。以BP网络为例,就是要确定网络的层数、每层的节点数、节点激活函数、初始权值、学习算法等。如前所述,这些选项有一定的指导原则,但更多的是靠经验和试凑。

对具体问题,若输入输出确定后,则网络的输入层和输出层节点数即可确定。关于隐层及其节点数的选择比较复杂。一般原则是:在能正确反映输入输出关系的基础上,应选用较少的隐层节点数,以使网络结构尽量简单。文献[63]给出了网络结构增长型和剪除型两类学习方法。前者是先设置较少的节点数,对网络进行训练,并测试学习误差,然后逐渐增加节点数,直到学习误差不再有明显的减少为止;后者是先设置较多的节点,在训练中,删除那些影响不大的连接权及相应的节点,最终得到一个规模适当的网络结构。另外,为了达到相同的映射关系,采用二个隐层的节点数常常要比只用一个隐层时少。因此,当通过上述方法得到的隐层节点数太多时,可考虑采用二个或多个隐层。

### 3. 训练与测试

最后一步是利用获取的训练样本对网络进行反复训练,直至得到合适的映射结果。这里应注意的是,并非训练的次数越多,结果就越能正确反映输入输出的映射关系。这是由于所收集到的样本数据都包含有测量噪声,训练次数过多,网络将噪声也复制了下来,反而影响了它的泛化能力。

我们知道,训练网络的目的是找出蕴涵在样本数据中的输入输出之间的关系,从而对未经过训练的数据也能给出正确的输出,即具备泛化能力。网络的泛化能力要通过一组独立的数据来进行测试和检验。测试时,保持网络的连接权不变,用测试数据作为网络的输入,正向运行网络,并检验输出的均方误差。实际操作时,通常采用训练过程和测试过程交替进行的方式,即每训练一次,用测试数据测试一遍,绘出均方误差与训练次数的关系曲线。可以看出,随着训练次数的增加,均方误差开始会减小,当训练次数再增加时,检验误差反而会增大。误差曲线上的极小点所对应的即为合适的训练次数。若再训练就可能造成“过度训练”了。

对网络隐层节点数的选择也应采取训练与测试相结合的方式,用测试误差来衡量网络的性能。网络的节点数对其泛化能力的影响很大,但并非节点数越多越好。节点数太多,网络会记住所有的训练数据,包括噪声的影响,反而降低了泛化能力;而节点数太少时,网络不能有效拟合样本数据,因而也谈不上良好的泛化能力。

在训练过程中,网络初始权值的选择可采用随机法产生。为避免产生局部极值,可选取多组初始权值,然后通过检验测试误差来选用一组较为理想的初始权值。

#### 2.4.2 BP 算法存在的缺陷

BP 算法因其简单、易行、计算量小、并行性强等优点,目前是神经网络训练采用最多也是最为成熟的训练算法之一。

BP 算法的实质是求解误差函数的最小值问题,由于它采用非线性规划中的最速下降方法,按误差函数的负梯度方向修改权值,因而通常存在以下问题。

##### 1. 学习效率低,收敛速度慢

首先,BP 算法是利用误差函数对权值的一阶导数信息来指导权值调整的,以求最终达到误差最小。在执行过程中,网络参数每次调整的幅度,均以与网络误差函数或其对权值的导数大小成正比的项乘以固定的因子  $\eta$  进行。这样,在误差曲面曲率较高处,这一偏导数值较大,网络参数调整的幅度也较大,以至于在误差函数最小点附近会发生过调整现象,使权值调节路径变为严重的锯齿形,难以收敛到最小点。为保证算法的收敛性,学习率  $\eta$  必须很小。这样在误差曲面较平坦处,由于偏导数值本身已较小,网络参数调节的幅度就更小,以至于需要经过多次调整才能将误差函数曲面降低。这是 BP 算法学习速度慢的一个重要原因。这一点从学习误差的变化中也不难看出。假定权值学习尚未到达极值点,将误差函数展开为 Taylor 级数,并取其一阶项,可得权值每次调整时学习误差的变化为<sup>[149]</sup>

$$\Delta E \equiv E(k+1) - E(k) \approx -\eta \left\| \frac{\partial E(k)}{\partial w} \right\|^2 \quad (2.55)$$

可见,权值学习愈接近极值点,误差变化愈慢,造成收敛速度很慢。

基本 BP 算法加入动量项后,学习速度有所提高。但应用中使用固定的动量因子,会在稳定点附近引起随机振荡,使学习过程很难精确收敛到稳定点。这种方法虽然可以在一定程度上提高学习速度,但对改善收敛效果,提高收敛精度,甚至摆脱局部极小没有太大的积极作用<sup>[150]</sup>。

其次,由于 BP 算法中权值的调整是沿误差函数梯度下降方向进行的,而多层前馈网络的高度非线性,使网络误差函数的 Hessian 阵具有严重的病态,使梯度的最速下降方法偏离指向误差曲面的最小点方向,从而加长了权值到达最小点的路径,自然增加了收敛时间。

此外,由于神经元的激活函数具有饱和非线性特性,在学习过程中,当神经元的输入进入非线性饱和区时,会出现饱和现象。此时,误差函数对权值参数的导数值很小(趋近于零),导致权值修改量很小。而实际上,网络的输出并没有达到其期望输出。有人将这种饱和称为“值饱和”或“平台”现象。一旦网络的学习进入“假饱和”状态,需要很长时间累积权值修改量,才能摆脱这种状态。“假饱和”现象不仅与神经元的输入状态有关,而且与神经元激活函数的形状有关<sup>[151]</sup>。

## 2. 易陷于局部极小状态

从数学角度看,BP 算法是以梯度下降法为基础的非线性优化方法,不可避免地存在局部极小问题。除非误差的平方和指标函数在权空间满足正定的要求,否则必然易于陷入局部极小点。

另外,实际问题的求解空间往往是极其复杂的多维曲面,存在着许多局部极小点,更使这种陷于局部极小点的可能性大大增加。通常,在 BP 算法中随机设置初始权值时,网络的训练一般较难达到全局最优。

## 3. 网络的泛化及适应能力较差

BP 算法中权值的学习采用绝对误差平方和为指标函数,因而只能降低各样本的绝对误差量,这势必造成各神经元在学习中的不平衡性<sup>[63]</sup>。如当样本中存在一些“非主导模式”时,即该模式对误差的贡献较小,依靠绝对形式的误差函数,这些非主导模式就很难对网络进行较好的训练,以至于网络对这些模式缺乏良好的响应,从而影响了网络的性能。事实上,由于实际系统的复杂性,在网络训练中,事先获取的训练样本很难覆盖系统可能具有的全部的模式特性。通过这些样本学习得到的模型在应用于实际时,推广特性自然较差。文献<sup>[151]</sup>还从解的收敛角度分析了 BP 网络的容错性能,指出容错能力差是 BP 算法本身所固有的。

# 2.5 增广 LPIDBP 学习算法

## 2.5.1 LPIDBP 学习算法的推导

对 BP 算法存在的收敛速度慢的问题,各国学者都提出了许多改进措施,如自适应调

整学习率加快 BP 算法的收敛速度<sup>[149,152,153]</sup>、采用变动量因子改善学习效果<sup>[154,155]</sup>等等。但文献[63]研究表明,单纯改变学习率或动量因子对改善学习效果均有一定局限,有时甚至不如基本 BP 算法,这与算法应用的具体问题有关。有人认为现有的关于权值的修正算法过于数学化、理论化,与人脑思维方式不完全一致,于是从选取新的误差函数、非线性输出函数等方面入手,研究神经网络的权值学习<sup>[46]</sup>,也都不同程度地加快了收敛速度。然而在大多数以梯度下降法为基础的学习算法中,对梯度的变化信息及长期工作(累积)信息未加以有效地利用。

R. Vitthal 受 PID 调节器原理的启发,直接利用误差梯度函数的比例、积分、微分组合形成调节量,如(2.56)式,我们称之为 RPIDBP 算法<sup>[156]</sup>。

$$\Delta W(k) = k_p G(k) + k_d \Delta G(k) + k_i \sum_{i=1}^k G(i) \quad (2.56)$$

其中:  $k_p$ 、 $k_i$ 、 $k_d$  为比例、积分、微分系数;  $G(k) = -\frac{\partial E(k)}{\partial W(k)}$ ;  $\Delta G(k) = G(k) - G(k-1)$  为当前梯度变化量。当仅有比例项存在时,(2.56)式与即成为标准 BP 算法。文献[157]从连续系统 PID 控制器离散差分方程入手,也得到了相应的 PID 形式的学习算法。RPIDBP 算法在理论上有一定新义,理解直观,但应用时人为确定的参数太多,且比例、积分、微分系数的选择对算法的收敛影响极大,不易取得最优设置。在连续系统的辨识与控制当中,这些系数还难以与控制误差、采样时间等取得明确的对应关系。

在神经网络梯度学习算法中,以梯度  $G(k)$  为调节量,达到调整被调节量  $\Delta W(k)$  的目的。受上述思想的启发,如果在其间增加比例、积分、微分组合作用的函数关系,则可能利用 PID 控制作用的原理,来达到快速调节的目的。为此,我们提出增广 LPIDBP 学习算法,其原理如图 2-9 所示。




图 2-9 LPIDBP 学习算法原理

设 PID 传递函数为:

$$D(s) = k_p \left( 1 + \frac{1}{T_i s} \right) + \frac{T_d s}{1 + \frac{T_d s}{a}} \quad (2.57)$$

其中  $k_p$  为比例增益;  $T_i$  为积分增益;  $T_d$  为微分常数;  $a$  为消除高频干扰而引入滤波器的常数,取值范围为(3,10)。设  $T$  为采样时间,对上述方程取一阶近似离散化后有<sup>[158]</sup>:

$$D(z) = k_p \left( 1 + \frac{T}{T_i} \cdot \frac{1}{z-1} + a \frac{z-1}{1+r_0} \right) \quad (2.58)$$

其中  $r_0 = \frac{aT - T_d}{T_d}$ 。

如图 2-9 所示,由 LPIDBP 算法原理可得

$$\Delta W(z) = D(z) G(z) \quad (2.59)$$

为提高差分方程精度,对(2.57)式取双线性变换,即令

$$S = \frac{2}{T} \cdot \frac{z-1}{z+1} \quad (2.60)$$

将(2.60)式代入(2.57)式,得



$$\begin{aligned}
D(z) &= k_p \left( 1 + \frac{T}{2T_i} \cdot \frac{z+1}{z-1} \right) + \frac{2T'_d}{T} \cdot \frac{z-1}{z+r} \\
&= k_1 + k_2 \frac{z^{-1}}{1-z^{-1}} - k_3 \frac{z^{-1}}{1+rz^{-1}}
\end{aligned} \quad (2.61)$$

其中,  $T'_d = T_d \frac{T}{T+2T_d/a}$ ,  $r = \frac{T-2T_d/a}{T+2T_d/a}$ ;

$$k_1 = k_p \left( 1 + \frac{T}{2T_i} \right) + \frac{2T'_d}{T}, \quad k_2 = \frac{T}{T_i}, \quad k_3 = (1+r) \frac{2T'_d}{T}.$$

将(2.61)式代入(2.59)式,可得 LPIDBP 学习算法的规则为

$$\begin{aligned}
\Delta W(k) &= (1-r)\Delta W(k-1) + r\Delta W(k-2) + k_1 G(k) \\
&\quad + (k_1(r-1) + k_2 - k_3)G(k-1) + (k_3 + k_2r - k_1r)G(k-2) \\
&= \alpha \Delta W(k-1) + \beta \Delta W(k-2) + b_0 G(k) + b_1 G(k-1) + b_2 G(k-2)
\end{aligned} \quad (2.62)$$

其中  $\alpha, \beta, b_0, b_1, b_2$  为常系数。满足如下的关系:

$$\begin{cases} \alpha + \beta = 1 \\ b_0 + b_1 + b_2 = k_2(r+1) \end{cases} \quad (2.63)$$

下面考查(2.56)式与(2.62)式的关系。由(2.56)式可得:

$$\Delta W(k-1) = k_p G(k-1) + k_d \Delta G(k-1) + k_i \sum_{i=1}^{k-1} G(i) \quad (2.64)$$

(2.56)式-(2.64)式有:

$$\begin{aligned}
&\Delta W(k) - \Delta W(k-1) \\
&= (k_p + k_i + k_d)G(k) - (k_p + k_i + 2k_d)G(k-1) + k_d G(k-2) \\
&= k_p G(k) + k_i G(k-1) + k_d G(k-2)
\end{aligned} \quad (2.65)$$

显然,上式体现的离散传递函数是有纯积分环节的二阶系统,容易产生积分饱和。而(2.62)式与上式相比,相当于增加了惯性项,因此可在一定程度上抑制振荡和积分饱和。

关于(2.62)式 LPIDBP 学习算法的收敛性,可以作如下简单分析。重写 BP 算法的权值学习公式如下

$$\Delta W(k) = \eta G(k) + \alpha \Delta W(k-1) \quad (2.66)$$

由上式可以得到

$$\Delta W(k-1) = \eta G(k-1) + \alpha \Delta W(k-2) \quad (2.67)$$

将上式代入(2.66)式,则 BP 学习算法为

$$\begin{aligned}
\Delta W(k) &= \eta G(k) + \alpha_1 \Delta W(k-1) + (\alpha - \alpha_1) \Delta W(k-1) \\
&= \eta G(k) + \alpha_1 [\eta G(k-1) + \alpha \Delta W(k-2)] + (\alpha - \alpha_1) \Delta W(k-1) \\
&= \eta G(k) + \alpha_1 \eta G(k-1) + (\alpha - \alpha_1) \Delta W(k-1) + \alpha_1 \alpha \Delta W(k-2) \\
&= \eta G(k) + \alpha_1 \eta G(k-1) + (\alpha - \alpha_1) \Delta W(k-1) + c_1 \Delta W(k-2) \\
&\quad + c_2 \Delta W(k-2)
\end{aligned} \quad (2.68)$$

其中  $\alpha_1, c_1, c_2$  为常系数,且  $c_1 + c_2 = \alpha_1 \alpha$ 。

比较(2.62)式与(2.68)式,当(2.62)式中的  $b_2 = 0$  时,(2.62)式与(2.68)式的惯性 BP 算法一致;当  $b_2 \neq 0$  而  $G(k-2) = c_2/b_2 \Delta W(k-2)$  时,则(2.62)式与(2.66)式完全一

致。我们已知,传统 BP 算法和惯性 BP 算法是收敛的。因此 LPIDBP 算法的收敛性也可得到保证<sup>[159]</sup>。

另外,由上面的推导说明,LPIDBP 算法是惯性 BP 算法与滞后两拍的 BP 算法的合成。由于采用了依据 PID 控制原理的参数配置,LPIDBP 算法可以有效克服 BP 算法的振荡和积分饱和的影响,避免惯性 BP 算法在收敛区域的不灵敏性,加速收敛,有利于动态系统实时辨识和控制。

(2.62)式包含了神经网络权值学习系数与采样时间、积分时间、微分时间常数等之间的关系,便于与连续系统对应。显然 LPIDBP 要比 RPIDBP 学习参数的物理意义更加清晰。同时由于引入了惯性项,可以在较大的学习参数下加快收敛而减少振荡和发散的可能。按照上述构造神经网络学习算法的思路,从设计滤波器和传递函数的角度,我们还可以构造 Kalman 滤波器等其他传递函数方程,从而得到其他形式的神经网络学习算法。本节内容希望能起到抛砖引玉的作用。

### 2.5.2 仿真研究

考虑二阶非线性离散动态系统

$$y(k+1) = \frac{0.875y(k) + u(k)}{1 + y^2(k) + y^2(k-1)} \quad (2.69)$$

假定该系统未知,目的是训练一神经网络代表其正向动力学模型,从而验证本节提出的 LPIDBP 算法的有效性。仿真中,由区间  $\{-0.5, 0.5\}$  上随机产生 400 个数据对,作为训练样本集。训练准则定为输出的均方误差和,即  $\frac{1}{2} \sum e^2$ 。训练方法采取以下三种:①BP 网络与 BP 算法;②BP 网络与 LPIDBP 算法;③复合输入 DRNN 与 LPIDBP 算法。其中复合输入 DRNN 网络结构为  $(1+6) \times 6 \times 1$ ,自反馈系数 0.25,反馈系数 0.5,前向滤波系数 0.9;BP 网络结构为  $3 \times 6 \times 1$ ,BP 算法的学习率  $\eta = 0.01$ ,动量因子  $\alpha = 0.1$ ;取采样周期  $T=0.1$  秒。采用 LPIDBP 算法时,为简化运算,仅对输出层权值采用 LPIDBP 算法,对隐层权值仍沿用标准 BP 算法。

图 2-10 是采用上述几种网络和学习算法的训练情况。其中曲线 1 是 BP 网络采用 BP 算法的收敛结果;曲线 2 是 BP 网络采用 LPIDBP 算法的收敛结果;曲线 3 是复合输入 DRNN 采用 LPIDBP 算法的收敛结果。通过比较可以看出,LPIDBP 算法较 BP 算法具有明显的优势,同时曲线 3 有最佳的学习散果,说明复合输入 DRNN 的稳态收敛精度高于 BP 网络。

为验证复合输入 DRNN 的泛化能力,在图 2-10 的学习结果下,对网络和系统分别施加幅度为 0.5、频率分别为 0.1Hz 和 0.5Hz 的正弦输入,其响应情况分别如图 2-11 和 2-12 所示。可见,在不同的频率下,复合输入 DRNN 的输出均能很好地逼近系统的响应。表明网络的泛化能力较高。适当调整采样时间和 LPIDBP 参数,收敛速度和辨识精度会更加理想。

另外,我们通过上例对 Elman 网络进行了仿真研究,结果发现,图 2-5 所示的改进的 Elman 网络几乎不具备泛化能力,仅能满足系统对给定的光滑输入函数的辨识。在图 2-10 的学习中,其误差平方和函数值始终保持在 15.3 左右而不收敛,这一点与前文的分




图 2-10 收敛速度比较




图 2-11 0.1Hz 正弦输入响应




图 2-12 0.5Hz 正弦输入响应

析一致。但是,应当指出,系统实时辨识和控制大多是在给定输入信号下进行,因此 El-

man 网络仍有一定的作用,尤其在需要利用它的导数逼近能力的时候。

## 2.6 全局寻优自适应快速 BP 学习算法

目前在神经网络的学习中,基于梯度的算法都不能从理论上保证收敛结果是全局最优的。为了得到全局最优的前馈网络训练算法,许多研究者提出采用随机优化技术,如模拟退火法<sup>[43]</sup>、趋药分类法<sup>[44]</sup>、Alopex 算法<sup>[160]</sup>、遗传算法<sup>[161]</sup>等训练神经网络。这些算法都是随机优化的批量算法,不易在线执行。文献[63,162,163]把递推最小二乘(RLS)技术应用于多层前馈网络的训练,能得到全局最优解,并易于在线执行,但算法执行过程中,计算量和存贮量都远超过基本 BP 算法,给具体应用带来了困难。

本节根据梯度算法中网络权值的演化规律,并基于终端吸引子<sup>[164]</sup>,提出一种能全局寻优的自适应快速 BP (Globally Convergent Adaptive Quick Back Propagation, 简称 GCAQBP)算法,并进一步给出改善 GCAQBP 算法训练效果的一些措施。

### 2.6.1 GCAQBP 学习算法的推导

先给出如下定义和设定。

**定义 2.1** 设神经网络的实际输出及其目标输出分别为  $y_i$  和  $y_{di}$ ,则网络的输出误差函数为

$$E = \frac{1}{2} \sum_{i=1}^{N_L} (y_i - y_{di})^2 \quad (2.70)$$

若记神经网络输出误差函数对权值向量  $W$  的梯度为  $\nabla_W E$ ,则根据梯度法,网络权值对时间的演化规律可记为

$$\frac{dW}{dt} = -\eta \nabla_W E \quad (2.71)$$

其中  $\eta$  为小的正数。

在时间  $t$  的微小变动下,网络权值的变化可记为

$$\Delta W(t) = W(t + \Delta t) - W(t) \quad (2.72)$$

利用 Taylor 级数,将上式展开为二阶近似形式

$$\Delta W(t) \approx \dot{W}(t) \Delta t + \frac{1}{2} \ddot{W}(t + \xi \Delta t) \Delta t^2 \quad (2.73)$$

其中  $\xi \in (0,1)$ 。

将(2.73)式进行离散处理,并作一阶逼近得

$$W(k+1) - W(k) = \dot{W}(k) \quad (2.74)$$

考虑到(2.71)式,有

$$W(k+1) = W(k) - \eta \nabla_W E(k) \quad (2.75)$$

显然,(2.75)式从形式上看就是标准的 BP 算法, $\eta$  为学习率。

考虑 BP 算法中误差和误差梯度信息对权值调整的综合影响,学习率  $\eta$  取为如下自适应形式:

$$\eta = \lambda \frac{E^\mu}{\|\nabla_w E\|^2} \quad (2.76)$$

其中  $\lambda > 0$  为学习率增益;  $0 < \mu < 1$ ;  $\|\nabla_w E\|$  为网络误差函数对权值梯度向量的范数, 其计算可在信息反向传播过程中进行:

$$\begin{aligned} \|\nabla_w E\|^2 &= \sum_{l=2}^L \sum_{i=1}^{N_l} \sum_{j=1}^{N_{l-1}} \left( \frac{\partial E}{\partial w_{ij}^l} \right)^2 \\ &= \sum_{l=2}^L \sum_{i=1}^{N_l} \sum_{j=1}^{N_{l-1}} \left( \frac{\partial E}{\partial y_i^l} \frac{\partial y_i^l}{\partial x_i^l} \frac{\partial x_i^l}{\partial w_{ij}^l} \right)^2 \\ &= \sum_{l=2}^L \sum_{i=1}^{N_l} \sum_{j=1}^{N_{l-1}} (\delta_i^l)^2 (\sigma'(x_i^l))^2 (y_j^{l-1})^2 \end{aligned} \quad (2.77)$$

其中:  $y_i^l$  为第  $l$  层第  $i$  个节点的输出值;  $x_i^l$  为第  $l$  层第  $i$  个节点的激活值;  $w_{ij}^l$  为第  $l-1$  层第  $j$  个节点到第  $l$  层第  $i$  个节点的连接权值;  $N_l$  表示第  $l$  层的节点数;  $L$  为总层数;  $\sigma(\cdot)$  为节点的激活函数。

总结以上推导, 可得以下 GCAQBP 算法的计算公式:

$$w_{ij}^l(k+1) = w_{ij}^l(k) - \eta \delta_i^l(k) \sigma'(x_i^l(k)) y_j^{l-1}(k) + \alpha \Delta w_{ij}^l(k) \quad (2.78)$$

$$\delta_i^l(k) = \begin{cases} y_i^l(k) - y_{di}(k) & (l = L) \\ \sum_{j=1}^{N_{l+1}} \delta_j^{l+1}(k) \sigma'(x_j^{l+1}(k)) w_{ji}^{l+1}(k) & (l = 1, 2, \dots, L-1) \end{cases} \quad (2.79)$$

为进一步改善网络学习效果, 采取如下措施:

### 1. 学习率的进一步修正

为避免初始学习时误差过大而造成的学习过程振荡, 以及个别受扰点大误差的影响, 增强学习过程的鲁棒性, 对学习率增益作如下修正:

$$\lambda = \frac{\lambda_0}{1 + E} \quad (2.80)$$

其中  $\lambda_0$  为初始学习增益。

### 2. 动量因子的调整

当学习率自适应变化时, 为有效避免学习过程产生振荡, 加快收敛速度, 动量因子  $\alpha$  的取值原则为

$$\alpha = \begin{cases} \alpha & (\Delta E < 0) \\ 0 & (\Delta E > 0) \end{cases} \quad (2.81)$$

### 3. 假饱和现象的消除

为消除假饱和现象, 网络初始权值取得尽可能小; 网络输入数据作归一化处理, 减少神经元进入饱和状态的机会; 网络输出层采用线性作用函数, 此时输出层神经元不存在饱和问题, 同时可将神经网络逼近的非线性映射关系的输出值域扩大至  $(-\infty, \infty)$ ; 隐层采用对称 Sigmoid 函数, 函数值域扩大至  $(-1, 1)$ , 可对零输入样本进行训练<sup>[63]</sup>。

#### 4. 网络适应能力的改善

在复杂系统控制中,任何预先设计好的训练数据都难以覆盖实际系统所有可能的模式,因此,为提高网络的适应能力,保证网络在实际应用中具有良好的推广特性,采用动态数据集对网络进行在线跟踪训练,做到对系统的跟踪逼近。使用时,训练数据随控制周期动态更新。

结合以上措施,GCAQBP 算法的实现过程如下:

① 网络及训练参数初始化。

- 给出训练参数  $\lambda_0, \mu, \alpha_0$ 。
- 网络初始权、阈值在  $[-0.1, 0.1]$  之间随机选取。
- 对网络输入信息进行归一化处理。

② 正向传播计算。根据网络输入,计算网络输出((2.11)式)。

③ 反向传播计算。

- 计算反向误差信号  $\delta_j$ ((2.79)式)。
- 计算误差函数对权值梯度向量的范数((2.77)式)。
- 计算  $\eta(t), \alpha(t)$ ((2.76), (2.80), (2.81)式)。

④ 更新权值((2.78)式)。

⑤ 判断训练是否满足精度和学习时限要求,若满足精度要求,则应用;不满足,且时限未到,返回步骤②;否则更新训练数据,返回步骤②。

#### 2.6.2 GCAQBP 学习算法性能分析

对 GCAQBP 学习算法的收敛情况,有如下定理:

**定理 2.5** 若定义网络的输出误差函数如(2.70)式所示,则利用(2.76)式~(2.81)式来训练神经网络的权值,可使神经网络的输出误差达到最优。

证明:由神经网络输出误差函数的定义(2.70)式可知

$$\frac{dE}{dt} = (\nabla_w E)^T \frac{dW}{dt} \quad (2.82)$$

将(2.71)式代入(2.82)式,并利用(2.76)式,可得

$$\frac{dE}{dt} = (\nabla_w E)^T (-\eta \nabla_w E) = -\lambda E^2 \quad (2.83)$$

显然,由定义 2.1 可知  $E \geq 0$  正定,而由(2.83)式知  $dE/dt \leq 0$ ,则根据 Lyapunov 稳定性定理可知,必存在一组网络权值,使网络的输出误差为零,即  $E=0$ 。

证毕。

定理 2.5 也就是说,由(2.76)式~(2.81)式构成的学习算法用于神经网络训练时,将使学习过程收敛于全局最优值点  $E=0$ ,即  $E=0$  为方程(2.83)的一个平衡点或稳定吸引子。

实际上,由(2.76)式可以看出,当学习过程进入局部极小状态或“假饱和”状态时,误差函数的梯度信息  $\nabla_w E$  趋于零,但此时误差信息  $E$  依然存在,导致学习率  $\eta$  很大,从而使网络权值产生一个较大的调整,使系统迅速跳出局部极小点,而继续向最优值点演化。

下面来考查 GCAQBP 算法的收敛速度问题。由(2.76)式可知,学习率  $\eta$  随误差和误差函数对网络权值的梯度信息自适应调整。当网络误差较大时,学习步长相应增大,可有效加快收敛速度<sup>[149]</sup>;当网络输出误差减小后,学习率  $\eta$  自适应减小,可避免权值调整产生振荡。这一点也可以从每次学习后,网络输出误差的变化中看出。假定网络的学习尚未接近权值最优值点,将误差函数展开为 Taylor 级数并取其一阶项,可得每次学习后,网络输出误差的变化为

$$\Delta E \equiv E(k+1) - E(k) \approx -\lambda E^\mu \quad (2.84)$$

可见,适当地选择  $\lambda$  和  $\mu$ ,就可以控制学习误差变化的快慢,即可控制学习的收敛速度。

事实上,进一步考查(2.83)式,可以发现

$$\frac{dE}{dE} = -\lambda \mu E^{\mu-1} \quad (2.85)$$

考虑到  $0 < \mu < 1$ ,因此,当  $E \rightarrow 0$  时,有

$$\frac{dE}{dE} \rightarrow -\infty \quad (2.86)$$

这时,方程(2.83)在  $E=0$  点违反 Lipschitz 条件,因此,  $E=0$  不是系统(2.83)的渐近吸引子而是终端吸引子(Terminal Attractor)<sup>[164,165]</sup>。利用终端吸引子的特性,此时,对任意初始误差  $E_0$ ,经过网络权值演化,使方程(2.83)的解  $E$  收敛于  $E=0$  所需的时间必定为有限,即

$$t = \int_{E_0}^0 -\frac{dE}{\lambda E^\mu} = \frac{E_0^{1-\mu}}{\lambda(1-\mu)} < \infty \quad (2.87)$$

也就是说,随学习率增益  $\lambda$  的自适应调整,神经网络的学习过程将在有限时间内产生收敛,从而可大大提高训练速度。

由上述分析可知,GCAQBP 算法有以下显著特点:

① 算法具有全局最优性,但计算量与存贮量仅与基本 BP 算法相当,便于实时应用。在推导上没有作任何假设,理论上具有良好的完整性,可适用于采用 BP 算法训练的一切前馈网络。

② 利用误差和误差梯度信息自适应调整学习率,使误差函数  $E=0$  成为误差演化方程的终端吸引子,而非渐近吸引子,网络的学习过程可在有限时间内产生收敛。

③ 学习率增益随误差函数值作自适应调整((2.80)式),拓宽了初始学习步长的选择范围,且能有效避免控制过程中个别受扰点大误差的影响,降低了学习过程对学习步长的灵敏度,增强了学习过程的鲁棒性。

应当指出,在导出(2.75)式时,用了 Taylor 级数展开式的一阶逼近,因此,应用中有时得到的不是全局最优解,而是次优解。

## 2.7 本章小结

(1)本章从控制角度,描述了神经元模型,给出了本书控制系统研究中用到的几个神经网络模型及其学习算法,并结合 DRNN 和 BP 网络的特点,提出了复合输入 DRNN 模

型,不仅有利于提高网络的收敛速度和泛化能力,而且可望用较小的网络结构实现对高阶系统的辨识与控制。

(2)以 MFNN 为例,分析了神经网络的逼近能力;说明了 BP 算法存在的缺陷,指出不仅学习率和动量因子会影响 BP 算法的学习效果,而且学习中存在的“假饱和”现象会严重影响收敛速度。

(3)根据 PID 控制器的调节原理,提出了增广 LPIDBP 学习算法,与 RPIDBP 算法相比,该算法的学习参数具有明确的物理意义,且由于增加了惯性项,有利于减少学习过程产生振荡和发散的机会,做到加快收敛。

(4)根据 BP 算法训练过程中网络权值的演化规律,提出一种可全局寻优的自适应快速训练算法——GCAQBP 学习算法。理论分析表明,该算法具有全局最优性,训练速度快,鲁棒性强,且计算量和存贮量仅与基本 BP 算法相当,非常适用于实时应用。这种方法在第四、六和十一章的仿真和实时控制中取得了成功的应用。



### 第三章 非线性系统的神经网络辨识

由前一章的分析可知,神经网络在逼近任意非线性连续函数方面具有巨大的优越性。因此,20世纪80年代末以来,将神经网络作为一种崭新的非线性模型引入复杂系统的辨识中,引起了许多学者的广泛关注<sup>[59,67,166,167]</sup>。本节就从理论和实践两方面来讨论一下应用神经网络进行复杂系统辨识的可行性及其实现方法。

#### 3.1 系统辨识的基本概念

系统建模与辨识是进行控制系统设计的基本前提。传统的系统建模方法是在理论分析的基础上,建立对象的机理模型。而对复杂系统,要得到这样的模型是非常困难的。因此,人们常依靠实验的方法,从实验观测数据中建立能够反映系统输入-输出关系的模型。这就是系统辨识研究的问题。用这种方法得到的模型,其参数可能不具有明确的物理意义,然而这并不影响我们利用该模型进行控制系统的设计。

通常,一个实际系统可认为是从某输入空间到某输出空间的一个算子, $f: \Omega_u \rightarrow \Omega_y$ ,它属于某一个算子类 $F$ 。该算子通常是未知的,隐含定义在系统的输入-输出数据对中 $\{u(t), y(t) | t \in [0, T]\}$ 。也就是说,系统特性是通过输入-输出数据对来表现的。系统辨识问题是指,对于一个给定的算子类 $F$ 和其中一个对象 $f \in F$ ,确定一个模型类 $F_m$ , $F_m$ 可以是 $F$ 的一个子集,也可以是不同的集合;然后从中找到一个特定的元素 $f_m \in F_m$ ,通过对系统输入-输出数据对的处理,使 $f_m$ 对某一给定的 $\epsilon > 0$ ,有下式成立:

$$\|y - y_m\| = \|f(u) - f_m(u)\| \leq \epsilon, u \in \Omega_u \quad (3.1)$$

其中 $\|\cdot\|$ 是输出空间 $\Omega_y$ 中的范数, $y = f(u)$ , $y_m = f_m(u)$ 分别是系统和模型对 $u$ 的响应。

L. A. Zadeh对辨识所下的定义为:“辨识就是在输入和输出数据的基础上,从一组给定的模型中,确定一个与所测系统等价的模型。”这个定义明确了辨识的三个基本要素:

① 合适的模型集。从中可选出一个合适的模型,能在某种期望的程度上代表被辨识系统。模型集可以是根据机理建模所得到的具有某些未知参数的模型结构,也可以是参数待定的黑箱模型结构。

② 合适的观测数据。辨识系统时,要有一组能反映系统特性的输入-输出可观测数据,观测数据可通过对具体对象进行实验获得。一般地,要求在满足系统约束的前提下,尽可能使观测数据具有最大的信息量。这就是系统的充分激励问题。

③ 合适的评价准则。用以从模型集合中确定一个特定的模型,使之与当前观测数据达到最佳逼近,也即辨识的优化目标。

实际上我们不可能寻找到一个与实际系统完全等价的模型。从实用的角度来看,辨识就是从一组模型中选择一个模型,按照某种准则,使之能最好地拟合由系统的输入/输出观测数据体现出的实际系统的动态或静态特性。

## 3.2 非线性系统神经网络辨识的可行性

### 3.2.1 非线性系统辨识模型

#### 1. 状态-输出模型

设系统的动态方程为:

$$\left. \begin{aligned} x(k) &= f[x(k-1), u(k-1)] \\ y(k) &= h[x(k)] \end{aligned} \right\} \quad (3.2)$$

其中:  $u(k)$  为系统的控制输入;  $x(k)$ 、 $y(k)$  分别为系统的状态和输出;  $f(\cdot)$ 、 $h(\cdot)$  为未知非线性函数。

由系统理论可知, 对系统(3.2), 可以采用以下两种状态-输出辨识模型:

$$\left. \begin{aligned} x_m(k) &= f_m[x(k-1), u(k-1)] \\ y_m(k) &= h_m[x(k)] \end{aligned} \right\} \quad (3.3)$$

$$\left. \begin{aligned} x_m(k) &= f_m[x_m(k-1), u(k-1)] \\ y_m(k) &= h_m[x_m(k)] \end{aligned} \right\} \quad (3.4)$$

其中:  $x_m(k)$ 、 $y_m(k)$  分别为辨识模型的状态和输出;  $f_m(\cdot)$ 、 $h_m(\cdot)$  为非线性函数。对(3.3)式,  $f_m(\cdot)$ 、 $h_m(\cdot)$  都是静态的。而式(3.4)由于用到了模型自身的反馈, 构成了递归结构, 可以反映系统的动态行为, 又称为递归状态-输出模型。

状态-输出模型能描述相当一大类非线性动态系统。在辨识时, 要求系统的状态和输出都可测。

#### 2. 输入-输出模型

由于要求系统的所有状态和输出都可测, 因此状态-输出模型实用性欠佳。实际上, 我们常采用非线性自回归滑动平均模型进行系统辨识<sup>[59,167]</sup>, 即 NARMAX 模型

$$y_m(k) = f_m(y(k-1), \dots, y(k-n); u(k-1), \dots, u(k-m)) \quad (3.5)$$

这一模型是基于当前最新观测数据, 对系统输出的一步超前预报, 所以称为系统的一步预报模型。可以看出, 即使整个系统是动态的, 式中  $f_m(\cdot)$  也是静态的。

由于 NARMAX 模型不能存储状态信息, 而仅取决于系统的输入输出的延迟值, 因而它的表达能力大大低于状态输出模型。如果不能用系统的输入输出信息来重构系统的状态, NARMAX 模型将不能描述给定的系统。为了改善 NARMAX 模型的表达能力, 类似状态-输出模型, 用模型输出来代替对象的输出, 形成如下的 NARMAX 模型<sup>[59]</sup>

$$y_m(k) = f_m(y_m(k-1), \dots, y_m(k-n); u(k-1), \dots, u(k-m)) \quad (3.6)$$

这一模型称为系统的估计模型, 也是系统的并行模型。式中  $f_m(\cdot)$  取决于模型自身的输入输出值, 因此比较适合于含有噪声的系统, 可避免实际系统输出含有噪声而造成的有偏问题。但是, 如果辨识模型存在误差, 这一误差也会通过自反馈递归过程产生累积效应, 而引起较大的估计偏差。

### 3.2.2 非线性系统辨识模型的神经网络实现

复杂系统中的被控对象是难以用机理模型来表示的, 需要从对象运行过程中采集到

的输入-输出数据对中,通过系统辨识的方法建立对象模型。如前所述,系统辨识的首要因素是确立对象所属的模型集。对复杂系统,由于存在非线性、不确定性和未知性等诸因素的影响,对象的模型集通常是未知的,因此常采用黑箱模型结构来进行辨识。对于黑箱辨识方法,虽然对象所属的算子集是未知的,但对象却隐含定义在系统的输入-输出对中,因此,可以认为它属于非线性连续算子集合。故而在确定对象的模型集时,选用对连续算子集合具有任意逼近能力的模型集合即可。这就为神经网络进行系统辨识提供了可能。

为考察用神经网络实现非线性系统辨识模型的可行性,先给出以下假设:

**假设 3.1** 若定义系统控制输入  $u(t)$  的取值范围为集合,  $\Omega_u \subset R^m$ , 那么,  $\forall u \in \Omega_u$ ,  $x_0 \in R^p$ , 对有限的  $M$ , 恒有  $\|X(M)\| + \|Y(M)\| < \infty$ , 即系统是稳定的。

**假设 3.2** 对式(3.3)和(3.4), 函数  $f_m: R^{m+p} \rightarrow R^p$  和  $h_m: R^{m+p} \rightarrow R^n$  是连续的, 且满足 Lipschitz 条件; 对(3.5)式和(3.6)式, 函数  $f_m: R^{n+m} \rightarrow R^n$  是连续的, 且满足 Lipschitz 条件; 即系统的解是惟一的。

**假设 3.3**  $\forall \epsilon > 0$ , 对任意的连续函数  $g: C \rightarrow R^n$  (其中  $C \subset R^n$  为一紧集), 均存在参数为  $W^*$  的多层前馈神经网络, 使网络的输出  $NN_g(X, W^*)$  满足

$$\max_{x \in C} \|NN_g(X, W^*) - g(X)\| < \epsilon \quad (3.7)$$

这一条件可以由 2.3 节的多层前向神经网络的逼近定理直接得到。

### 1. 状态-输出模型的神经网络实现

由上一节的分析可知, (3.3)式中的状态-输出模型由两个独立的静态非线性函数  $f_m(\cdot)$ ,  $h_m(\cdot)$  组成, 因此可用多层前向网络来逼近。也就是说, 在对象状态和输出可测的条件下, 该模型可由两个多层前向网络来实现, 即有定理 3.1。

**定理 3.1** 对(3.3)式的状态-输出模型所示系统, 若满足假设 3.1 和 3.2, 则  $\forall \epsilon_x, \epsilon_y > 0$ , 必存在参数为  $W_f$  和  $W_h$  的两个多层前向神经网络

$$\left. \begin{aligned} x_N(k) &= NN_f[x(k-1), u(k-1), W_f] \\ y_N(k) &= NN_h[x(k), W_h] \end{aligned} \right\} \quad (3.8)$$

使得  $\forall u \in \Omega_u, x \in R^p$  和正整数  $M$ , 有下式成立

$$\begin{aligned} \max_{k \in [0, M]} \|x_N(k) - x(k)\| &< \epsilon_x \\ \max_{k \in [0, M]} \|y_N(k) - y(k)\| &< \epsilon_y \end{aligned}$$

定理 3.1 可由假设 3.3 直接证得。在辨识过程中,  $NN_f(\cdot)$  和  $NN_h(\cdot)$  的训练可采用如图 3-1 所示结构。训练算法可以采用第二章介绍的各种方法。




图 3-1 状态-输出模型的神经网络辨识结构

与(3.3)式的状态-输出模型不同, (3.4)式状态方程的输出是前一时刻状态和输入的

函数,存在一种递归关系, $f_m(\cdot)$ 不再是静态的,因此必须用递归网络来实现。对(3.4)式的输出方程,由于其输出是当前时刻状态和输入的函数,仍可以用一多层前向网络来实现,为此有如下定理<sup>[168]</sup>。

**定理 3.2** 由满足假设 3.3 的两个神经网络串-并接组成的系统

$$\left. \begin{aligned} x_N(k) &= NN_f[x_N(k-1), u(k-1), W_f] \\ y_N(k) &= NN_h[x_N(k), W_h] \end{aligned} \right\} \quad (3.9)$$

若  $x_N(0) = x(0) = x_0 \in R^n$ ,  $u \in \Omega_u \subset R^m$ , 那么  $\forall \varepsilon > 0$ , 必存在网络参数  $W_f$  和  $W_h$ , 使得  $\forall u \in \Omega_u$  和正整数  $M$ , (3.9) 式的输出与满足假设 3.1 和假设 3.2 的 (3.4) 式所示系统的输出充分接近, 即

$$\max_{k \in [0, M]} \|y_N(k) - y(k)\| < \varepsilon$$

定理 3.2 指出, 如果对象的状态和输出可测, (3.4) 式所示模型可由两个神经网络串-并接在一起来实现。其中  $NN_f(\cdot)$  要采用递归神经网络学习算法进行训练,  $NN_h(\cdot)$  的训练可用 BP 算法进行。由于  $NN_f(\cdot)$  的输出作为  $NN_h(\cdot)$  的输入, 因此采用的训练结构如图 3-2 所示。




图 3-2 递归状态-输出模型的神经网络实现

由图 3-2 可知, 如果仅是对象的输出可测或仅有少数状态可测,  $NN_f(\cdot)$  将因缺少目标输出而不能采用已提出的算法进行训练。这时 (3.9) 式是不可实现的。为此, 文献[63]提出一种称作状态空间辨识模型的神经网络结构, 如图 3-3 所示。该结构由一个多层前向网络和一个递归神经网络串-并连接而成, 它将递归状态-输出模型 (3.4) 的两个非线性函数统一在一起。其优点是网络内神经元的物理概念明确, 训练时仅需对象输出的测量值, 而无需对象状态的观测值。




图 3-3 神经网络状态空间辨识模型

## 2. 输入-输出模型的神经网络实现

对(3.5)式描述的系统模型,即使整个系统是动态的,模型的输入-输出映射关系  $f_m(\cdot)$  也是静态的,所以由假设 3.3 可知,  $y_m(t)$  可直接用一多层前馈网络来实现,即有如下的定理:

**定理 3.3** 对(3.5)式所示系统,若满足假设 3.1 和假设 3.2,则  $\forall \epsilon > 0$ ,必存在一参数为  $W$  的多层前向神经网络

$$y_N(k) = NN_f(y(k-1), \dots, y(k-n); u(k), \dots, u(k-m); W) \quad (3.10)$$

使得  $\forall u \in \Omega_u \subset R^m, y \in \Omega_y \subset R^n$  和正整数  $M$ ,均有下式成立:

$$\max_{k \in [0, M]} \|y_N(k) - y(k)\| < \epsilon$$

该定理的证明可由假设 3.3 直接得到。

对(3.6)式描述的并行 NARMAX 模型,其输入-输出映射关系  $f_m(\cdot)$  不再是静态的,而是与系统的历史输入输出相关的非线性动态函数,因此必须用递归神经网络来实现。文献[169]就这一问题进行了讨论,并给出了用神经网络实现几种特殊形式的非线性系统辨识的可行性证明。

## 3.3 非线性系统的神经网络辨识方法

### 3.3.1 概述

由上一节的分析可以看出,神经网络用于系统辨识的实质是选择一适当的神经网络模型来逼近实际系统。与基于算法的辨识方法一样,神经网络辨识也离不开模型、数据和误差准则等三大要素。

#### 1. 模型的选择

从某种意义上讲,模型是对实际系统的一种近似描述,当然越精确越好,但一味追求精确,模型就会变得十分复杂,以至没有实际意义。如果适当降低模型的精度要求,忽略次要因素,模型就可以简单些,在计算量和求解上就体现出优势。所以在建立实际系统的模型时,要兼顾精确性和复杂性两方面的因素。既要考虑到模型能对系统进行精确逼近,又不至于过于复杂而使运算量巨增,这就需要在二者之间作些折中处理。反应到神经网络模型的构造上,主要是两络层数和各层节点数的确定。一般地,网络输入和输出层节点数可由具体问题而定,一种最直接的方法是将模型的输入-输出结构选得与系统的一样,如对(3.5)式所示系统,模型的结构可以选为(3.10)式所示。这样输入和输出层节点数就确定下来了。至于隐层及其节点数的确定,目前尚无较好的理论指导,除了已提出的一些结构训练算法外<sup>[18,63]</sup>,通常还是通过仿真实验来确定。因此,可根据具体问题的要求,在精确性和复杂性之间作一些折中取舍。通过仿真实验,找出能在给定的准则下逼近原系统的最简单的网络模型。

#### 2. 输入信号的选择

对动态系统而言,为了得到系统的辨识模型,输入信号必须满足一定的条件。通常要

求在辨识时间内,输入信号能持续激励系统的动态过程,即系统的所有模态都能被所选择的输入信号充分激励;从频谱上讲,即要求输入信号的频谱必须足以覆盖系统的频谱。其次,要求输入信号的选择能使给定系统的辨识模型精度最高,即所谓最优输入信号设计问题。为此在利用神经网络辨识非线性动态系统的研究中,一般选择白噪声或伪随机信号作为系统的输入信号。但值得注意的是,不是所有实际系统都可以用白噪声或伪随机信号作为系统的输入信号,以获得神经网络的训练数据<sup>[159]</sup>。

### 3. 误差准则的选择

误差准则是用来衡量模型接近实际系统的标准,通常表示为误差的泛函,记做

$$J = \sum_{k=1}^r f(e(k)) \quad (3.11)$$

其中  $f(\cdot)$  是  $e(k)$  的函数,采用最多的是平方函数,即

$$f[e(k)] = e^2(k) \quad (3.12)$$

$e$  是定义在区间  $(0, r)$  上的误差函数。这个函数可广义地理解为模型与实际系统的“偏差”,它可以是输出误差,也可以是输入误差或其他广义误差。

#### (1) 输出误差

当实际系统和神经网络模型的输出分别记做  $y(k)$  和  $y_N(k)$  时,则

$$e(k) = y_N(k) - y(k) = NN_f[u(k)] - y(k) \quad (3.13)$$

称为输出误差。它通常是模型参数的非线性函数(神经网络模型的参数表现为其权值),因此在这种误差准则意义下,辨识问题归结成非线性最优化问题。利用传统的算法辨识方法确定最优解时,需要用梯度法、牛顿法或共轭梯度法等优化方法,辨识过程比较复杂。而神经网络具有处理非线性优化问题的能力,且其信息处理的并行化决定了这种方法具有较快的速度,因此在神经网络辨识中,通常采用这种误差准则。

#### (2) 输入误差

若记产生输出  $y(k)$  的模型输入为  $u_N(k)$ ,则定义

$$e(k) = u_N(k) - u(k) = NN_f^{-1}[y(k)] - u(k) \quad (3.14)$$

为输入误差。其中  $NN_f^{-1}$  表示假定模型是可逆的,即总可以找到一个产生给定输出的惟一输入。这时  $e(k)$  也是模型参数的非线性函数,对于算法式辨识,辨识过程也是比较复杂的,误差准则难以实用。但是作为神经网络辨识模型,其参数即为网络的权值,可通过神经网络学习算法进行调节,因此只要系统是可逆的,则总可以找到一个多层网络,在这一误差准则下逼近系统的逆  $NN_f^{-1}$ 。

#### (3) 广义误差

在一般的情况下,误差可以定义为

$$e(k) = NN_2^{-1}[y(k)] - NN_1[u(k)] \quad (3.15)$$

其中  $NN_2^{-1}$ 、 $NN_1$  叫做广义模型,且模型  $NN_2^{-1}$  是可逆的,这种误差称为广义误差。它一般是模型参数的线性函数,目前大多数辨识算法都采用这一准则。利用神经网络可以分别实现模型  $NN_1$  和  $NN_2^{-1}$ 。

从上面的讨论可以看出,系统辨识实际上是一个最优化问题,优化准则的选择依赖于辨识的目的与辨识算法的复杂性等因素。传统辨识算法的基本原理就是通过建立系统的

依赖于参数的模型,把辨识问题转化为对模型参数的估计问题。这类算法能较为成功的应用于线性系统或本质线性系统。

但是对于本质非线性系统,上述的辨识算法已难以付诸应用。而神经网络用于系统辨识的一个优点就是不需要预先建立实际系统的辨识格式,它对系统的辨识过程就是直接学习系统的输入输出数据的过程。学习的目的是使所要求的误差准则函数达到最小,从而归纳出隐含在系统输入输出数据中的映射关系。这个关系就是描述系统动态或静态特性的算子  $f(\cdot)$ 。当学习完成后,  $f(\cdot)$  隐含在神经网络内部,其表现形式如何,对外界而言是不可知的。这一点与神经网络辨识的目的是一致的。因为人们所关心的并不是神经网络以什么样的形式去逼近实际系统  $f(\cdot)$ ,而只要神经网络的输出  $NN_f(\cdot)$  在(3.1)式所表示的意义下能够逼近系统在同样输入信号激励下的输出  $f(u)$ ,则认为神经网络已充分描述了实际系统的特性并完成了对原系统的辨识。一般的,基于输出误差的神经网络辨识原理如图 3-4 所示。




图 3-4 神经网络辨识原理图

与传统的基于算法的辨识方法相比较,神经网络用于系统辨识具有以下几个特点:

① 神经网络本身作为一种辨识模型,其可调参数反映在网络内部的连接权上,因此不再要求建立实际系统的辨识格式,即可以省去对系统建模这一步骤。

② 可以对本质非线性系统进行辨识,而且辨识是通过在网络外部拟合系统的输入/输出数据、而在网络内部归纳隐含在输入/输出数据中的系统特性来完成的,因此这种辨识是由神经网络本身来实现的,是非算法式的。

③ 辨识的收敛速度不依赖于待辨识系统的维数,只与神经网络本身及其所采用的学习算法有关,传统的辨识算法随模型参数维数的增大而变得很复杂。

④ 由于神经网络中的神经元之间存在大量的连接,这些连接上的权值在辨识中对应于模型参数,通过调节这些权值即可使网络输出逼近系统输出。

⑤ 神经网络作为实际系统的辨识模型,实际上也是系统的一个物理实现,可以用于在线控制。

### 3.3.2 非线性静态系统的神经网络辨识

#### 1. 神经网络辨识结构

静态模型是用来描述动态系统处于稳态时(各状态变量的各阶导数均为 0)的各状态变量之间的关系,这些变量一般不是时间的函数。在静态模型辨识中,最常用的方法是回

归分析。它用统计方法来研究一个随机变量与另一个(或一组)变量之间的关系。多层网络作为一个非线性映射,其内部包含大量的非线性处理单元和权连接,而且只要隐层处理单元足够多,则一定能够找到一个网络内部表达,使得网络能执行任何从输入到输出的匹配。于是我们可把实际系统看作一个黑箱,用神经网络来模拟系统的外部静态特性,从而使网络的输入/输出与实际系统的输入/输出相拟合。由于BP算法可以通过误差反向传播来自动学习网络的内部表达,因此可将实际测得的待辨识系统的输入输出数据作为样本送入结构已定的多层网络中进行学习,以确定网络内部各节点之间连接的强度,学习完成后,多层网络的结构和权值即可确定下来,而充当系统的一个模型。

一个具有  $n$  维输入矢量和  $m$  维输出矢量的非线性静态系统,可看作是从其输入空间到输出空间的一个非线性算子矩阵。设该系统可由下列的非线性方程来描述:

$$\begin{cases} y_1 = f_1(x_1, x_2, \dots, x_n) \\ y_2 = f_2(x_1, x_2, \dots, x_n) \\ \dots\dots\dots \\ y_m = f_m(x_1, x_2, \dots, x_n) \end{cases} \quad (3.16)$$

对上述系统,通常可有二种或两种以上的神经网络辨识结构。图3-5和图3-6分别给出了采用  $m$  个多层网络和单个多层网络的辨识结构。

图3-5中第  $i$  个神经网络的输出记为  $y_{Ni}$ ,它通过逼近系统的第  $i$  个输出  $y_i$  建立起系统的一个子模型( $i=1, 2, \dots, m$ ),  $m$  个子模型一起构成实际系统的一个神经网络辨识模型,以完成对系统的辨识。其中第  $i$  个神经网络的学习准则为  $J_i = e_i^2 = (y_{Ni} - y_i)^2$ 。图3-6中应用单个神经网络的  $m$  个输出同时逼近系统的  $m$  个输出,以完成对系统的辨识,其中神经网络的学习准则为  $J = \sum_{i=1}^m J_i$ 。




图 3-5 多神经网络辨识结构




图 3-6 单神经网络辨识结构

下面来比较一下神经网络辨识方法与回归分析法的差异。

我们知道,回归分析法通过把实际系统分解为多个子模型的线性组合来逼近原系统的静态特性,最终将辨识问题转化为参数估计问题,所要估计的参数就是各个子模型的组合系数。子模型越多,辨识的精度就会越高,但相应的辨识模型就会越复杂。那么如何确定这些子模型呢?

线性静态系统可用下列线性回归模型来拟合:

$$y = b_0 + b_1 x_1 + \dots + b_m x_m \quad (3.17)$$



其中  $b_i (i=0, 1, \dots, m)$  为未知参数,  $x_i (i=0, 1, \dots, m)$  为输入变量,  $y$  为输出变量。由最小二乘原理求  $b_0, b_1, \dots, b_m$ , 使

$$J(b_0, b_1, \dots, b_m) = \sum_{i=1}^n [y_i - (b_0 + b_1 x_{1i} + \dots + b_m x_{mi})]^2 \quad (3.18)$$

最小, 式中  $x_{ji}, y_i (i=1, 2, \dots, n; j=1, 2, \dots, m)$  为实际量测的系统输入/输出数据,  $n$  为数据长度。这样便可求出未知参数  $b_0, b_1, \dots, b_m$  的估计值, 从而得到原系统的模型

$$\hat{y} = \hat{b}_0 + \hat{b}_1 x_1 + \dots + \hat{b}_m x_m$$

对于大多数非线性系统, 如果其非线性程度不是很高, 一般可采用多项式函数所描述的模型来逼近, 这时子模型由所选择的基函数描述, 所要估计的参数即为基函数的系数, 即

$$f(x) = b_0 \varphi_0(x) + b_1 \varphi_1(x) + \dots + b_m \varphi_m(x)$$

其中基函数系  $\{\varphi_k(x)\} (k=0, 1, \dots, m)$  可取正交函数系, 基函数取多少项要视系统的非线性程度而定。这样就可利用线性回归分析法对系统作最小二乘拟合, 求出未知参数  $b_i$  的估计值  $\hat{b}_i (i=0, 1, \dots, m)$ , 系统的数学模型就辨识出来了, 即

$$\hat{f}(x) = \hat{b}_0 \varphi_0(x) + \hat{b}_1 \varphi_1(x) + \dots + \hat{b}_m \varphi_m(x) \quad (3.19)$$

然而对于多输入/多输出系统, 情况常常比较复杂, 系统中可能不仅有高次项, 而且还有交叉项, 如系统  $y = a_1 x_1 + a_2 x_2 + a_3 A x_1^2 + a_4 x_1 x_2$ 。如何判断有哪些变量的高次项及交叉项出现? 基函数要取多少项(对应于选择多少个子模型), 模型误差才不至于太大? 这就需要在选定用来建模的拟合函数之前, 先对系统中各变量做相关性分析, 删除那些次要的、对输出影响较小的变量, 从而选择一适当形式的函数作为拟合函数。这一过程中要用到相当的经验知识, 而且受算法复杂性的影响, 基函数项不能取得太多。对这样一类系统, 神经网络辨识方法有以下特点:

① 由于神经网络信息存储的分布性, 它将在整个网络中自动增强那些与输入模式相匹配的输出模式, 而其余的模式则被抑制; 各个输入变量对输出变量的相关程度将通过整个网络的内部表达而自动确定, 从而省去了通常建模之前所需要的对各变量的相关性分析。

② 神经网络可以连续学习, 当发现模型与实际系统间的逼近程度不符合要求时, 它可以在原来的基础上继续学习, 进一步提高辨识精度, 或在原来的基础上增加新的样本继续学习, 使模型与系统进一步逼近。

③ 神经网络自身的非线性使得它用来辨识非线性系统成为一自然的选择, 且这种方法不需选取基函数系。在对静态系统辨识时, 网络只关心系统外部的输入/输出特性, 用什么样的拟合函数来逼近系统对神经网络来说是无足轻重的, 因为网络通过学习, 其内部权值连接就反映出隐含在输入/输出数据中系统的静态特性。

## 2. 仿真研究

考虑非线性函数

$$y(x_1, x_2) = x_1 + x_1^2 + x_1^2 x_2 + x_1 x_2^2 \quad (3.20)$$

其中:  $x_1 \in [-1, 1], x_2 \in [-0.5, 0.5]$ 。要求用静态 BP 网络来辨识这一非线性函数。

取网络结构为  $2 \times 6 \times 1$ , 训练数据采用 21 对均匀分布的数据对  $((x_1, x_2), y)$ 。经过

600 次学习后,网络的输出结果如图 3-7 所示。图中  $y_n$  表示学习后神经网络的输出, $y$  为非线性函数的输出,Error 表示两者之差,可见神经网络对 21 个样本的训练是成功的。为验证网络的泛化能力,采用上面训练好的神经网络对新的输入样本进行拟合,设  $x_1 \in [-0.5, 0.5], x_2 \in [-0.5, 0.5]$ , 仍取均匀分布的 21 对数据,网络输出和非线性函数输出如图 3-8 所示,二者的偏差较大。




图 3-7 神经网络特定样本训练结果




图 3-8 神经网络测试结果

由仿真可以看出,为了得到较好的函数辨识结果,学习样本必须足够丰富,而且尽量覆盖所有可能的取值区域。图 3-9 是用随机数据对神经网络训练的结果,图 3-10 给出了训练后的网络对上述同一测试数据的输出响应结果,显然图 3-10 比图 3-8 的逼近结果有所改善。增加训练样本数和学习训练次数,神经网络逼近非线性函数(3.20)式的效果会更加理想。




图 3-9 随机样本训练结果




图 3-10 神经网络测试结果

### 3.3.3 非线性动态系统的神经网络辨识

#### 1. 辨识结构

本节讨论非线性动态系统的神经网络辨识方法。不失一般性,以非线性离散时间动态系统为例。这类系统可用非线性差分模型来描述,系统的输出量可能受到噪声干扰。针对不同形式的非线性差分模型所描述的系统,可以采用不同的神经网络辨识结构。

考虑下列四种非线性差分模型所描述的(SISO)系统:

$$(M1) \quad y(k) = A(q^{-1})y(k) + g[u(k-d), \dots, u(k-m-d)] + C(q^{-1})w(k)$$

$$(M2) \quad y(k) = f[y(k-1), \dots, y(k-n)] + q^{-d}B(q^{-1})u(k) + C(q^{-1})w(k)$$

$$(M3) \quad y(k) = f[y(k-1), \dots, y(k-n)] + g[u(k-d), \dots, u(k-m-d)] + C(q^{-1})w(k)$$

$$(M4) \quad y(k) = f[y(k-1), \dots, y(k-n); u(k-d), \dots, u(k-m-d)] + C(q^{-1})w(k)$$

式中

$$A(q^{-1}) = a_1 q^{-1} + a_2 q^{-2} + \cdots + a_n q^{-n}$$

$$B(q^{-1}) = b_0 + b_1 q^{-1} + \cdots + b_m q^{-m}, b_0 \neq 0$$

$$C(q^{-1}) = c_0 + c_1 q^{-1} + \cdots + c_l q^{-l}$$

$\{w(k)\}$  为白噪声序列, 时滞时间  $d \geq 1$  已知,  $f$  和  $g$  分别是适当的非线性算子,  $u(k)$  和  $y(k)$  分别为  $k$  时刻系统的输入和输出, 为了能利用神经网络对上面的系统进行辨识, 假定:

①时滞算子多项式  $B$  和  $C$  的阶次已知。

②  $C(q^{-1})$  为稳定多项式, 即其所有零点都位于单位圆内。

③系统是稳定的, 即它对于给定有界输入的输出应是有界的(BIBO 系统), 反映在模型  $M1$  上, 就是多项式  $z^n - a_1 z^{n-1} - \cdots - a_{n-1} z - a_n$  的根应全部位于单位圆内。

④系统是最小相位系统, 反映在模型  $M2$  上, 就是要求  $B(q^{-1})$  的零点全部位于单位圆内。

⑤  $\{u(k-i), i=0, 1, \cdots\}, \{y(k-j), j=0, 1, \cdots\}$  可测。

基于以上假设, 可以利用一般回归网络模型来描述一个非线性动态系统, 并结合动态误差反传学习算法, 完成对实际系统的辨识。下面给出描述非线性动态系统( $M1 \sim M4$ ) 的神经网络辨识模型。

对于上述模型所描述的系统, 可有两种神经网络辨识模型: 一是并行模型, 二是串-并模型。以  $M3$  为例, 并行模型可描述为:

$$y_N(k) = NN_f[y_N(k-1), \cdots, y_N(k-n)] + NN_g[u(k-d), \cdots, u(k-d-m)] \quad (3.21)$$

式中  $y_N(k)$  是神经网络辨识模型的输出,  $NN_f$  和  $NN_g$  代表神经网络所实现的算子。该模型在  $k$  时刻的输出依赖于它在  $k$  时刻以前的输出和系统的输入。尽管已假设待辨识系统是稳定的(BIBO 系统), 然而在学习开始并不能保证  $y_N$  逼近  $y$ , 若存在偏差, 那么这种偏差在递归过程中会产生累积效应。因此这种结构可能不稳定。

串-并模型的神经网络描述为

$$y_N(k) = NN_f[y(k-1), \cdots, y(k-n)] + NN_g[u(k-d), \cdots, u(k-d-m)] \quad (3.22)$$

该模型在  $k$  时刻的输出依赖于系统在  $k$  时刻以前的输入和输出。由于系统是 BIBO 系统, 所以神经网络的输入信号及在辨识中用到的其他信号均有界, 只要适当选择学习率的大小, 就能保证整个辨识结构的稳定性, 并期望  $y_N(k)$  逼近  $y(k)$ 。

串-并模型的神经网络辨识结构如图 3-11 所示。图中  $e(k) = y_N(k) - y(k)$  为神经网络模型输出与系统输出之间的误差, 根据该项误差即可构造神经网络的学习准则。训练神经网络时, 通常在每一个采样周期令网络学习一次或  $N$  次, 适当的选择  $N$  对神经网络在线控制的精度是很重要的。

作为特殊情况, 当系统在  $k$  时刻的输出线性的依赖于它在  $k$  时刻以前的输入或输出时, 系统可由模型( $M1$ )或( $M2$ )描述。如果要求对模型线性部分的参数进行估计, 则可以将神经网络与传统的递推辨识算法结合起来, 用神经网络完成系统非线性部分的辨识,

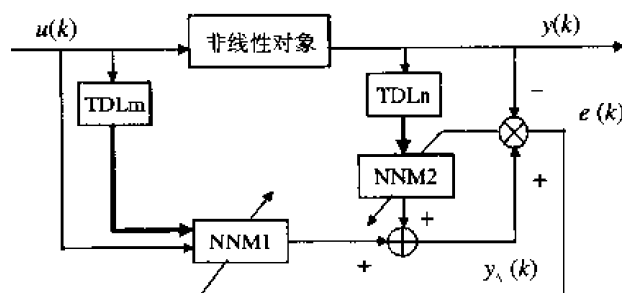


图 3-11 串-并模型的神经网络辨识结构

而用传统递推算法对系统线性部分的参数进行估计。下面以(M1)模型描述的系统为例作一简单介绍。

设该系统的辨识模型由下列差分方程描述

$$y_N(k) = \hat{A}(q^1)y(k) + NN_g[u(k-d), \dots, u(k-m-d)] \quad (3.23)$$

其中  $NN_g$  为神经网络实现的非线性算子，

$$\hat{A}(q^1) = \hat{a}_1 q^1 + \hat{a}_2 q^2 + \dots + \hat{a}_n q^n$$

$\hat{a}_i (i=1, 2, \dots, n)$  为  $a_i (i=1, 2, \dots, n)$  的估计值, 这些参数可由最小二乘算法得到。标准最小二乘格式为

$$\bar{y}(k) = \Phi^T(k-1)\theta \quad (3.24)$$

其中:

$$\begin{aligned} \bar{y}(k) &= y(k) - NN_g[u(k-d), u(k-d-1), \dots, u(k-d-m)] \\ \Phi^T(k-1) &= [y(k-1), y(k-2), \dots, y(k-n)] \\ \theta^T &= [\hat{a}_1, \hat{a}_2, \dots, \hat{a}_n] \end{aligned}$$

在一定的条件下, 当  $NN_g(\cdot)$  充分逼近  $g(\cdot)$  时, 这种辨识结构是稳定的, 并且线性算子的参数  $\hat{a}_i (i=1, 2, \dots, n)$  收敛到其真值。

多输入多输出(MIMO)系统的神经网络辨识可由上述方法稍加推广得到, 如考虑下列多输入多输出系统

$$\begin{cases} y_1(k) = f_1[y_1(k-1), y_2(k-1)] + g_1[u_1(k-d), u_2(k-1)] + w_1(k) \\ y_2(k) = f_2[y_1(k-1), y_2(k-1)] + g_2[u_1(k-d), u_2(k-1)] + w_2(k) \end{cases} \quad (3.25)$$

则可根据不同的目的和要求, 构造不同的神经网络辨识模型。如果只想得到一个能够模拟系统输入-输出特性的模型, 则用一个多层神经网络即可。该网络的输入矢量为  $[u_1(k-d), u_2(k-1), y_1(k-1), y_2(k-1)]$ , 输出矢量为  $[y_{N1}(k), y_{N2}(k)]$ , 它们分别逼近系统的输出  $y_1(k)$  和  $y_2(k)$ , 学习准则为

$$J = [y_{N1}(k) - y_1(k)]^2 + [y_{N2}(k) - y_2(k)]^2 \quad (3.26)$$

辨识结构如图 3-4 所示。

如果辨识的目的是为了设计神经网络控制器, 则仅用一个神经网络模拟系统的外部特性是不够的, 这时需要知道非线性算子  $f_1(\cdot), f_2(\cdot), g_1(\cdot), g_2(\cdot)$  的具体形式, 所以至

少需要 4 个神经网络,分别模拟上面的 4 个非线性算子。这样神经网络辨识模型可由下列方程来描述:

$$\begin{cases} y_{N1}(k) = NN_{f1}[y_1(k-1), y_2(k-1)] + NN_{g1}[u_1(k-d), u_2(k-1)] \\ y_{N2}(k) = NN_{f2}[y_1(k-1), y_2(k-1)] + NN_{g2}[u_1(k-d), u_2(k-1)] \end{cases} \quad (3.27)$$

其中网络  $NN_{f1}$  和  $NN_{g1}$  的学习准则为  $[y_{N1}(k) - y_1(k)]^2$ , 网络  $NN_{f2}$  和  $NN_{g2}$  的学习准则为  $[y_{N2}(k) - y_2(k)]^2$ 。辨识结构如图 3-12 所示。

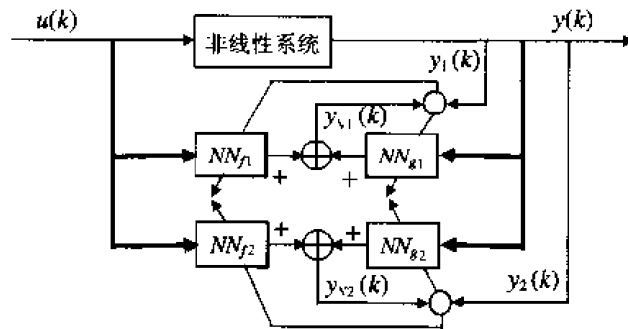


图 3-12 MIMO 系统的神经网络辨识结构

## 2. 仿真研究

考虑 SISO 非线性动态系统

$$y(k+1) = \frac{y(k)y(k-1)[y(k)+2.5]}{1+y(k)^2+y(k-1)^2} + u(k) \quad (3.28)$$

当输入信号为  $u(k) = \sin(2\pi k/80)$  时,系统输出如图 3-13 曲线  $y$  所示,可见系统的输出呈非线性变化。

采用复合输入动态递归网络对该系统进行辨识,网络结构取为  $1 \times 6 \times 1$ ,过程变化范围  $k=0,1,2,\dots,160$ ,学习次数为 1000 次,则神经网络输出如图 3-13 曲线  $y_n$  所示。为验证得到的模型的泛化能力,改变输入信号的频率,当  $u(k) = \sin(4\pi k/80)$  时,该神经网络




图 3-13 复合输入 DRNN 辨识结果

络辨识模型和非线性系统的输出如图 3-14 所示。由图可见,神经网络对(3.28)式所示非线性动态系统具有一定的跟踪精度。




图 3-14 复合输入 DRNN 的跟踪结果

### 3.4 神经网络在线自适应跟踪辨识

#### 3.4.1 辨识结构及方法

应用神经网络建立动态系统的模型,主要归功于神经网络所具有的对任意非线性映射的任意逼近能力。神经网络建模与辨识实质上是将神经网络作为实际系统的黑箱模型,利用系统的输入输出数据进行训练,使之与实际系统的特性相匹配。在模型结构确定的情况下,神经网络模型(NNM)的辨识过程就是神经网络模型(NNM)的学习训练过程。训练数据可以是系统运行的历史数据,也可直接在对象工作过程中,由系统的输入-输出采样数据得到。设对象的输入-输出对集合为 $\{u(k), y(k) | k = 1, 2, \dots, K\}$ ,则按照 NARMAX 模型形式,神经网络训练数据集可构造为:

$$\left\{ (Y, X) \left| \begin{array}{l} Y = y(k) \\ X = [y(k-1), \dots, y(k-n), u(k-1), \dots, u(k-m)]^T \end{array} \right. \right\} \quad k = K_0 + 1, \dots, K$$

式中  $K_0 = \max\{n, m\}$ 。在确定了训练准则后,NNM 就可以采用现有的各种学习算法进行训练了。

上述过程即使是在线进行的,但由于 NNM 辨识是利用现有的输入-输出数据进行的,因此从控制的本质上讲,仍是一种离线辨识方法。得到的 NNM 在一定模式范围内能反映外界扰动和噪声对系统的影响,也能反映系统内部扰动对实际系统性能的影响。但由于 NNM 是通过输入-输出数据训练得到的,本身是一种经验模型,缺乏物理基础;而且,离线辨识的依据是一组确定的采样数据,不可能反映出实际系统的全部特性,加之系统的时变、不确定性及非线性等因素的影响,系统的特性在不同的控制阶段也会产生相应的改变,即使经过充分训练的模型,在应用中也难以很好地反应系统的实际特性。那么能否针对系统在不同阶段的特性差异,给出相应的辨识模型呢? 这就是本节要讨论的跟踪

辨识问题。

跟踪辨识是采用递推辨识方法,在每一个采样时刻,量测到新的系统输入-输出数据,并利用这些数据来修正原有的模型,使 NNM 做到对系统的跟踪逼近<sup>[170,171]</sup>。这时,训练数据应为系统当前最新的输入-输出采样组合( $X(t)$ ,  $Y(t+1)$ )。

在系统控制中,一般要求系统能按给定轨迹运行,因此,不管系统本身的特性多么复杂,我们更为关心的是它在给定轨迹附近的特性。这就为神经网络在线自适应跟踪辨识提供了可能。在跟踪辨识中,要满足高精度控制的需要,要求 NNM 在每一个采样时刻,必须通过多次学习,做到对系统的精确逼近。然而这必然要增加控制系统的运算量,给系统的实时控制带来了新的问题。

我们知道,任何实际系统都可以看出是由已知规律和未知规律的两个部分组成。前者通常可用数学-物理模型来描述,也就是常说的机理模型。它是人们对实际系统内在规律的认识。由于在实际系统中,人们对客观事物的了解还不完备,机理模型大都在一定的假设条件下得到的,而且为便于应用往往都作了一定的简化处理,因此与实际系统之间存在着一定的建模误差。误差部分即为系统的未知规律,它是系统外部扰动和内部扰动共同作用的结果。误差部分的大小随系统的复杂程度而定。在上述神经网络建模与辨识中,神经网络将系统完全当作黑箱处理,而未利用实际系统的已知部分的规律。这显然是对人类通过智慧所取得的知识的一种浪费,而且形成的神经网络模型也缺乏相应的物理意义。

因此,如果将系统的已知规律的信息融合到神经网络建模中,而利用神经网络的学习能力和非线性映射能力估计出已知机理模型与实际系统的偏差,然后将其加到机理模型上,完成对系统的建模和辨识,那么得到的辨识模型不仅具有明确的物理意义,而且可大大减少神经网络辨识的在线运算量,有望做到对系统的实时跟踪辨识。文献[172,173]就是利用这种方法,将神经网络与系统的已知规律模型并行求和,取得了良好的建模效果。

基于上述思想,提出的神经网络在线自适应跟踪辨识结构如图 3-15 所示。图中,NNM1 可以是系统的机理模型或已知的估计模型,其结构和权值可以通过系统已知的先验信息事先确定,它反映的是系统的主特性,在辨识过程中,其权值一般不作调整;NNM2 为神经网络估计器,它在系统主运动轨迹附近辨识未知不确定因素对系统的影响,反映的是主特性所不能描述的动态信息。

可以看出,由于 NNM1 的作用,保证了系统的辨识过程沿着主特性进行,使辨识结果

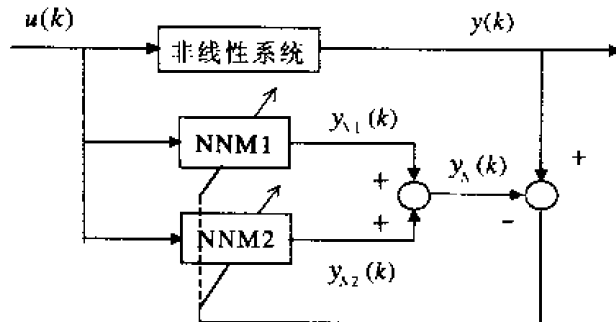


图 3-15 神经网络在线自适应跟踪辨识结构



的可靠性得到增强。而且在辨识过程中,神经网络只需要估计已知模型的误差,辨识范围大为缩小,运算量也大为减小,有利于提高网络的收敛速度。这两点保证了神经网络在线自适应跟踪辨识方法实用可行。

基于上述讨论,神经网络在线自适应跟踪辨识方法可实现如下:

- ① 初始化 NNM1、NNM2 结构、参数及各种学习参数。
- ② 在每一采样时刻  $k$ , 采样得到系统的输出值  $y(k)$ 。
- ③ 构造模型的输入向量  $X(k-1)$ , 并计算输出  $y_N(k) = y_{N1}(k) + y_{N2}(k)$ 。
- ④ 计算  $k$  时刻模型的输出偏差  $e(k) = y_N(k) - y(k)$ , 若  $\|e(k)\| < \epsilon$ , 则应用; 否则, 采用相应的学习规则修正  $(k-1)$  时刻的 NNM2 网络参数。
- ⑤ 令  $k = k + 1$ , 对  $\{y(k)\}$ 、 $\{u(k)\}$  进行移位处理, 返回步骤②。

与一般辨识方法相比,神经网络在线自适应跟踪辨识有以下特点:

- 采用在线跟踪辨识方法,神经网络模型就无需包含系统的全部特性(事实上也很难做到),因而网络结构不必选得过于庞大,有利于改善实时性。

- 由于主特性模型的作用,神经网络辨识范围大为缩小,辨识结果的可靠性更高,有利于控制系统设计。

- 当实际系统时变或产生扰动时,神经网络可在原来的基础上,对新的系统信息进行跟踪学习,从而达到对实际系统的精确逼近。

### 3.4.2 电液伺服系统仿真研究

如图 3-16 所示,仿真对象为阀控缸电液伺服弹簧质量系统,其中弹簧为非线性对象。




图 3-16 阀控缸电液伺服系统

设系统位移输出为  $x_p$ , 负载压力为  $p_l$ , 取状态变量为  $x_1 = x_p, x_2 = \dot{x}_p, x_3 = p_l$ , 则系统的状态方程为<sup>[159]</sup>

$$\dot{x}_1 = x_2 \quad (3.29)$$

$$\dot{x}_2 = [- (B_f x_2 + F) + A_e x_3] / m \quad (3.30)$$

$$\dot{x}_3 = \frac{4\beta_e}{V_t} [K_v i \sqrt{P_s - \text{sgn}(i)x_3} - A_e x_2 - C_l x_3] \quad (3.31)$$

其中  $i$  为控制输入

$$i = K_p(u - x_1) \quad (3.32)$$

$F$  为弹簧弹性力, 将其记为

$$F = k_1 x_1 + k_2 x_1^3 \quad (3.33)$$

式中各参量的物理意义及量值如表 3-1 所示。若记系统输出为  $y$ , 则

$$y = x_p \quad (3.34)$$

表 3-1 电液伺服系统参数表

参 量	数 值	参 量	数 值
系统油源压力 $P_s$	$5\text{e}^5\text{Pa}$	油液弹性模量 $\beta_c$	$1.4\text{e}^9\text{Pa}$
液压缸有效面积 $A_c$	$6.27\text{e}^{-3}\text{m}^2$	运动阻尼 $B_f$	$70\text{N/m/s}$
泄漏系数 $C_l$	$4.7\text{e}^{-13}\text{m}^3/\text{Ns}$	液压缸体积 $V_l$	$1.25\text{e}^{-3}\text{m}^3$
弹簧弹性系数 $k_1$	$7.5\text{e}^3$	放大器增益 $K_p$	$100\text{ A/m}$
弹簧弹性系数 $k_2$	$4.9\text{e}^4$	缸有效行程 $L$	$0.05\text{m}$
伺服阀综合放大系数 $K_v$	$9.04\text{e}^{-8}\text{l/s}$	等效运动质量 $m$	$1\text{e}^3\text{kg}$

采用复合输入动态递归网络对该系统进行动态自适应跟踪辨识。取网络结构为  $1 \times 6 \times 1$ , 自反馈系数 0.25, 反馈系数 0.5, 前向滤波系数 0.9, 采样时间为 0.01 秒, 每个采样周期内辨识训练次数为 100 次。图 3-17 为系统在  $3\text{rad/s}$  输入下的直接自适应跟踪辨识结果, 可见辨识效果比较理想。




图 3-17 直接自适应跟踪辨识

前面已经叙及, 在线性系统理论下, 对一般工程系统均作线性化近似处理。因此可以认为实际工程非线性系统均由一个线性模型与模外动态构成。若已知系统的线性化模型, 那么只要用神经网络辨识出模外动态, 也就实现了对系统的辨识。

简单地, 取上述电液伺服系统的线性模型为一阶模型, 传递函数为

$$G(s) = \frac{y_m(s)}{u_m(s)} = \frac{60}{s + 60} \quad (3.35)$$

采用与上述相同的辨识网络结构, 自适应跟踪辨识结果如图 3-18 所示, 其中  $y$  为系统输出,  $y_m$  为线性模型输出,  $y_n$  为神经网络辨识的模外动态, Error 为辨识误差。可以看出, 这种方法神经网络仅用于模外动态辨识, 网络的输出变化小, 精度优于图 3-17 所示结果。当线性模型比较准确时, 神经网络的输出可以限定在很小的区域内, 有利于网络的快

速收敛和系统的实时控制。




图 3-18 模外动态自适应跟踪辨识

### 3.5 本章小结

本章首先给出了系统辨识的一般概念,讨论了几种非线性动态系统的辨识模型及神经网络实现方法,从理论上说明了利用神经网络进行非线性动态系统辨识的可行性。在神经网络辨识中,神经网络(包括前向网络和递归动态网络)将确定某一非线性映射的问题转化为求解优化问题,而优化过程可根据某种学习算法通过调整网络的权值矩阵  $W$  来实现。

基于神经网络辨识的一般方法,本章给出了非线性静态系统和动态系统的神经网络辨识结构,并通过仿真证明了神经网络辨识的有效性。提出的基于工作点附近的神经网络在线自适应跟踪辨识方法,无需考虑激励信号的选择,可做到对系统的跟踪逼近。为提高神经网络辨识的实时性和可靠性,采用了系统主特性模型与神经网络叠加建模方法。神经网络只须辨识内、外部干扰所造成的模外动态,而无需包含系统的全部特性(事实上也很难做到),因而网络结构不必选得过于庞大,有利于改善实时性。另外,神经网络辨识是在主特性模型的基础上进行的,因此,其辨识范围大为缩小,辨识结果的可靠性更高,有利于控制系统的在线设计。将这一方法用于电液伺服系统的在线辨识,表明神经网络具有很好地跟踪系统输出变化的能力。此外,采用叠加法建模,对不同类系统或同类系统中的不同对象,只要修改主特性模型或其参数,神经网络就可以对不同的系统进行在线自适应跟踪辨识,具有良好的通用性。

## 第四章 神经网络并行自学习鲁棒自适应跟踪控制

### 4.1 引言

许多工业系统因其固有的不确定性和非线性特性,难以建立确切的数学模型,使传统控制理论在应用于实践时遇到了前所未有的困难<sup>[2]</sup>。另一方面,由于各种干扰的存在,系统的结构乃至参数都可能发生变化,因此即使依靠过程先验信息离线辨识得到了系统的模型,也难免存在模型失配问题。由此模型通过传统控制理论建立起来的控制方案用于在线控制时,因为未建模动态的影响,也难保持其原有的性能。自适应控制方法在一定程度上解决了不确定性问题,但其本质是对模型参数的在线辨识,需要知道对象的结构模型,这又使问题趋向复杂。

因此,如何在系统模型未知时,实现对系统的控制,一直是控制领域研究的焦点。这一问题的研究无论是对控制理论的发展,还是对控制理论在实践中的应用都具有重要的意义。

神经网络具有学习能力和逼近任意非线性映射的能力,为解决这类系统的控制提供了新的手段。近年来,国内外学者在将神经网络与传统技术相结合,应用于非线性、不确定性系统控制方面,进行了许多有益的尝试<sup>[174~178]</sup>,并取得了一些令人可喜的成果<sup>[179~184]</sup>。目前,在非线性系统的神经网络控制中,一般采用双神经网络(NN)结构<sup>[176~178]</sup>,其中一个NN作为被控对象的辨识模型,学习系统的正向动力学特性;另一个NN作为控制器,学习系统的逆动力学。这种方法在模型的精度足够高时,会获得很好的控制性能。通常,正向模型的学习比较简单,逆模型的学习相对复杂。但是,由于训练样本获取途径不同,模型的学习结果也有所差异。一般来说,用历史数据离线训练模型时,因训练样本难以覆盖实际系统可能的输入输出空间,难免存在未建模动态;通过实测数据进行在线训练时,由于NN需要分别辨识对象的正、逆动态,耗时较长。要保证控制的实时性,就无法保证NN的学习每次都能处于收敛状态,即无法保证NN能正确反映当前系统的正、逆动态特性,这势必影响系统的控制品质和稳定性。这一情况在控制初期、模型的精度较差时尤为严重。

本章针对模型未知的系统,提出一种神经网络并行自学习鲁棒自适应跟踪控制(Neural Networks Parallel Self-Learning Robust Adaptive Tracking Control,简称NNPSLRATC)结构。这是一个复合控制结构,利用神经网络的学习能力和非线性映射能力,解决传统自适应控制中模型的在线辨识和控制器的在线设计问题,以达到对不确定非线性系统的高精度输出跟踪控制;通过引入运行监控器,克服神经网络控制方法通常存在的实时性差的问题;利用一个鲁棒反馈控制器,来保证神经网络模型学习初期闭环系统的稳定性。本章还利用这一结构,分别对电液力伺服加载系统和位移伺服加载系统进行了仿真和实验研究。结果表明提出的控制结构是有效的<sup>[185,186]</sup>。

## 4.2 跟踪控制问题描述

考虑 SISO 系统

$$y(k) = f(y(k-1), \dots, y(k-n_y); u(k-1), \dots, u(k-n_u)) \quad (4.1)$$

其中:  $u \in \Omega_u \subset R^{n_u}$  为系统的控制输入;  $y \in \Omega_y \subset R^{n_y}$  为系统的输出;  $n_y, n_u$  分别为系统的阶次;  $f(\cdot)$  通常是未知非线性时变函数。

系统的跟踪控制问题可描述为: 确定控制率  $u(k)$ , 使系统输出  $y(k)$  渐进逼近其期望输出  $y_d(k)$ , 即

$$\lim_{k \rightarrow \infty} (y(k) - y_d(k)) = 0 \quad (4.2)$$

在工程应用中, 我们通常希望系统的输出能在有限控制周期内逼近其期望输出, 即

$$y(k) = y_d(k) \quad k \geq N \quad (4.3)$$

这一问题又称为精确跟踪问题。一般地, 精确跟踪问题可归结为: 在  $k$  时刻, 确定控制率  $u(k)$ , 使得  $(k+1)$  时刻系统的输出  $y(k+1) = y_d(k+1)$ , 其中  $y_d(k+1)$  为已知的期望曲线。

对方程(4.1), 确定控制率  $u(k)$  的过程就是对非线性函数  $f(\cdot)$  求逆的过程。然而, 在实际应用中, 由于  $f(\cdot)$  未知且不确定, 因此不能直接从中求取  $u(k)$ 。一个新的解决思路是: 利用神经网络来实现被控系统的辨识模型。即系统模型采用如下的神经网络模型(NNM):

$$y_m(k) = NN_f(y_m(k-1), \dots, y_m(k-n_y); u(k-1), \dots, u(k-n_u)) \quad (4.4)$$

其中  $y_m(k)$  是神经网络模型 NNM 的输出。如果 NNM 的辨识误差足够小, 则 NNM 的输出就可以作为实际系统的输出预测。于是, 控制器设计就可以基于 NNM 进行了。这时, 求系统的逆, 即求解  $u(k)$ , 就可以转化为求解 NNM 的逆。而求解 NNM 的逆可以通过求解代数方程(4.4)而得到。在实际控制中, 这种求逆计算可以在每个采样周期内进行。这样, 基于神经网络模型的在线辨识, 就可以进行跟踪控制律的在线设计了。本章将基于这一指导思想, 研究未知不确定非线性系统(4.1)的跟踪控制问题。

## 4.3 神经网络并行自学习鲁棒自适应跟踪控制器设计

### 4.3.1 控制器结构及工作原理

提出的并行自学习鲁棒自适应跟踪控制器是由一个并行结构来实现的, 它包括实时鲁棒自适应跟踪控制系统、神经网络并行自学习系统和运行监控器三个部分组成, 结构如图 4-1 所示。

实时控制部分相当于一个被动自适应鲁棒控制系统, 完成被控对象的实时控制和系统模型(ANNM)的在线辨识。并行自学习部分由系统的预测神经网络模型(PNNM)和一个结构与实时神经网络控制器(NNC)完全相同的神经网络自学习控制器(NNSLC)组成, 它根据在线辨识得到的 ANNM 独立地对系统输出进行预测, 并优化整定神经网络自学习控制器(NNSLC)的参数。其中 PNNM 的结构与参数和 ANNM 一样。这两个部

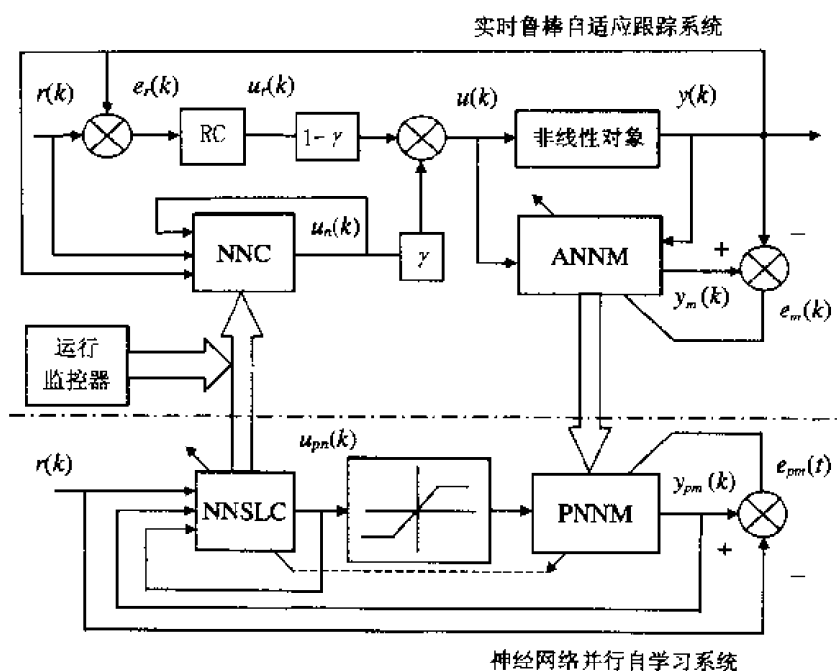


图 4-1 神经网络并行自学习鲁棒自适应跟踪控制结构

分是并行工作的。运行监控器的作用是协调两个并行结构的工作,它根据系统控制品质的变化,适时地将自学习控制参数切换至实时控制器,从而实现实时控制器的在线动态设计。

这里,ANNM 和 NNC 均由一个多层前馈神经网络 MFNN 组成,ANNM 通过在线训练学习系统动力学,不断逼近系统的非线性前馈映射特性;NNC 通过在线学习逼近系统的逆动力学,并产生一前馈控制信号,使系统的输出按要求的精度跟踪任意给定的输入波形。

在实时控制部分,考虑到系统是时变和不确定的,特别是控制初期,ANNM 尚未得到很好的训练,为保证闭环系统的稳定性和良好的控制效果,实时控制器由一个神经网络控制器 NNC 和一个鲁棒控制器 RC 组成,两个控制器的输出信号通过加权综合后,作为系统的控制输入,构成一个变鲁棒控制器

$$u(k) = \gamma u_n(k) + (1 - \gamma) u_r(k) \quad (4.5)$$

其中:为  $u_n(k)$  为 NNC 的输出;  $u_r(k)$  为鲁棒控制器的输出;  $\gamma$  反应的是系统模型 ANN 的辨识精度,称之为鲁棒因子。鲁棒因子的取值随 ANN 精度的变化而自适应改变,形式为

$$\gamma = e^{-\tau E_m} \quad (4.6)$$

式中  $\tau$  是鲁棒因子的变鲁棒系数,取值范围为  $\tau \in (0, 1)$ ;  $E_m$  为 ANN 输出与系统实际输出差的平方:

$$E_m = \frac{1}{2} (y_m - y)^2 \quad (4.7)$$

由(4.6)式可知,鲁棒因子的取值范围是  $\gamma \in [0, 1]$ 。  $\gamma = 1$  表示 ANN 辨识精度很高,可

准确地反映被控对象的特性;  $\gamma=0$  表示 ANNM 的精度很差, 此时不能作为控制器设计的依据。

这样, 由(4.5)式构成的控制器, 当 ANNM 高精度逼近被控对象时, 基于 ANNM 设计的 NNC 能取得良好的跟踪效果; 当 ANNM 的精度较低时, 由于鲁棒因子的作用, 削弱了 NNC 的控制作用, 而依靠鲁棒控制器的作用, 亦能确保闭环控制系统的稳定性。

系统的工作原理是: 在控制初期, ANNM 和 NNC 未得到训练, 其输出均为很小的随机值, 鲁棒控制器对系统实施反馈控制, 并保证闭环系统稳定。随着控制过程的继续, ANNM 不断学习被控对象的前馈特性, 并将学习后的网络参数传送 PNNM。PNNM 模型的参数在每一个采样周期中, 随着 ANNM 的调整而不断更新, 直至完全收敛。同时, 神经网络在线自学习控制器 NNSLC 根据每一控制周期中得到的 PNNM, 通过一个并行结构, 独立地对对象的逆动力学进行学习, 并利用运行监控器的协调作用, 不断地将网络参数(该参数亦在每一控制周期中不断更新, 直至完全收敛)切换至实时 NNC, 逐步提高 NNC 对系统的控制作用。随着训练次数的增多, ANNM 逐渐完善, 精度逐步提高; NNC 也逐渐逼近对象的逆动态, 对系统的控制作用将随着 ANNM 精度的提高呈指数增长。同时, 鲁棒控制器所起的作用逐渐削弱。当 ANNM 完全描述了对象的动态时, 训练后的 NNC 也将能完全描述对象的逆动态, 从而可独立地对系统实施高精度的跟踪控制。

#### 4.3.2 自适应神经网络模型(ANNM)及其训练

##### 1. ANNM 的构造

构造 ANNM 的目的是, 通过对系统输入-输出数据集的学习, 产生一非线性映射关系, 来逼近对象的前馈动力学。其作用是在控制器设计中, 用来训练 NNC 并进行误差信号的反传。

考查形如(4.1)式所示的 SISO 非线性动态系统, 该系统可看作是一个从  $(n_y + n_u)$  维输入空间到一维输出空间的非线性映射。根据第三章的神经网络建模与辨识方法, 则该系统的神经网络模型 ANNM 可描述为

$$y_m(k+1) = NN_f(X(k), W_m) \quad (4.8)$$

其中  $X(k) = [y(k), \dots, y(k - n_y + 1); u(k), \dots, u(k - n_u + 1)]^T$  为输入向量;  $y_m(k+1)$  为 ANNM 的输出;  $W_m$  为 ANNM 的权参数矩阵。由 2.3 节的结论, 我们采用一单隐层线性输出的 NN 来实现上述非线性关系。网络结构如图 4-2 所示。

假定  $N_m^I$ 、 $N_m^H$  分别表示 ANNM 输入层和隐层节点数,  $x_{m-j}^I$  表示模型输入层第  $j$  节点的输入,  $x_{m-i}^H$ 、 $y_{m-i}^H$  表示模型隐层第  $i$  节点的输入和输出,  $w_{m-i}^{OH}$ 、 $w_{m-j}^{HI}$  分别表示隐层到输出层和输入层到隐层的权值。略去各节点的阈值参数, 则 ANNM 的输入-输出映射关系为:

$$x_{m-i}^H = \sum_{j=1}^{N_m^I} (w_{m-ij}^{HI} x_{m-j}^I) \quad (4.9)$$

$$y_{m-i}^H = \sigma(x_{m-i}^H) \quad (4.10)$$

$$y_m = \sum_{i=1}^{N_m^H} (w_{m-i}^{OH} y_{m-i}^H) \quad (4.11)$$




图 4-2 单隐层线性输出神经网络结构

其中

$$\sigma(x) = \frac{1 - e^x}{1 + e^x}。$$

## 2. ANNM 的训练

ANNM 的训练就是通过对样本的学习,调整网络参数  $W_m$ ,使其所构成的非线性映射关系  $NN_f(\cdot)$ 逼近对象的动力学  $f(\cdot)$ 。训练数据  $D_m = \{X(k), y(k+1)\}$ 可以利用系统控制操作的历史数据,也可以是直接在线获得的实时测量数据。训练结构如图 3-4 所示。

为使模型输出与实际对象输出之间的误差最小,定义 ANNM 的训练目标函数为

$$E_m = \frac{1}{2N} \sum_{i=1}^N (y_{mi}(k+1) - y_i(k+1))^2 \quad (4.12)$$

其中  $N$  是训练数据集的样本数量。上式表示在  $N$  拍采样控制时间中,利用系统的  $N$  步控制信息并行完成一次辨识过程。在实时控制中,  $N$  通常取为 1,即每一采样控制周期对模型进行一次训练。

训练方法采用 3.4 节提出的 NNM 在线自适应跟踪辨识方法。ANNM 的权值修正公式可由 2.6 节的 GCAQBP 算法导出为:

$$\Delta w_{m-i}^{OH}(k+1) = -\eta_m \delta_m(k) y_{m-i}^H(k) + \alpha_m \Delta w_{m-i}^{OH}(k) \quad (4.13)$$

$$\Delta w_{m-ij}^{HI}(k+1) = -\eta_m \delta_{m-i}^H(k) x_{m-j}^I(k) + \alpha_m \Delta w_{m-ij}^{HI}(k) \quad (4.14)$$

$$\delta_m(k) = y_m(k+1) - y(k+1) \quad (4.15)$$

$$\delta_{m-i}^H(k) = \sigma'(x_{m-i}^H(k)) \delta_m(k) w_{m-i}^{OH}(k) \quad (4.16)$$

$$\eta_m = \lambda_m E_m^\mu / \|\nabla_{W_m} E_m\|^2 \quad (4.17)$$

$$\|\nabla_{W_m} E_m\|^2 = \sum_{i=1}^{N_m^H} (\delta_m(k))^2 (y_{m-i}^H(k))^2 + \sum_{i=1}^{N_m^H} \sum_{j=1}^{N_m^I} (\delta_{m-i}^H(k))^2 (x_{m-j}^I(k))^2 \quad (4.18)$$

$$\lambda_m = \lambda_{m0} / (1 + E_m) \quad (4.19)$$

其中:  $\lambda_{m0}$  为 ANNM 的初始学习增益;  $\alpha_m$  是动量因子;  $0 < \mu_m < 1$ 。

ANNM 通过对系统输入-输出数据对的学习,不断地将对象特性存贮在网络的分布权中。当目标函数收敛到一个给定的精度时,训练过程暂时结束。这时我们认为 ANNM



已能很好地代表对象的特性。即在给定精度的意义上,有

$$\begin{aligned} y(k+1) &= f(X(k)) \approx y_m(k+1) = NN_f(X(k), W_m) \\ &\approx NN_f(X_m(k), W_m) \end{aligned} \quad (4.20)$$

其中

$$X_m(k) = [y_m(k), \dots, y_m(k - n_y + 1); u(k), \dots, u(k - n_u + 1)]^T。$$

### 4.3.3 神经网络控制器(NNC)及其训练

#### 1. NNC 的设计

为了使被控系统准确地跟踪任意给定的参考输入信号, NNC 的设计思想是: 构造一个神经网络模型, 通过对输入-输出数据对的学习, 不断逼近对象的逆动力学, 然后根据系统的理想输出, 产生相应的理想控制输入, 使系统的输出跟踪误差为零。这里, NNC 的作用就相当于对象的逆模型。

对式(4.1)所示系统, 逆模型可描述为

$$u(k) = f^{-1}(X_u(k)) = g(X_u(k)) \quad (4.21)$$

其中

$$X_u(k) = [y(k+1), y(k), \dots, y(k - n_y + 1); u(k-1), \dots, u(k - n_u + 1)]^T。$$

则 NNC 可用如下的非线性输入-输出关系来描述

$$u_n(k) = NN_g(X_u(k), W_c) \quad (4.22)$$

其中  $W_c$  是 NNC 的权参数矩阵。

考虑系统的未来输出  $y(k+1)$  是  $u_n(k)$  的函数, 不能直接用于(4.22)的控制律中。因此, 我们用这一时刻系统的期望输出, 也就是参考输入信号  $r(k+1)$  来代替  $y(k+1)$ , 这样, NNC 在物理上就可以实现了。控制方程为

$$u_n(k) = NN_g(X_{u_n}(k), W_c) \quad (4.23)$$

其中

$$X_{u_n}(k) = [r(k+1), y(k), \dots, y(k - n_y + 1); u_n(k-1), \dots, u_n(k - n_u + 1)]^T。$$

同样, 我们采用一单隐层线性输出的 NN 来实现上述非线性关系。其结构如图 4-2 所示。假定  $N_c^I, N_c^H$  分别表示控制网络输入层和隐层节点数,  $x_{c-j}^I$  表示控制网络输入层第  $j$  节点的输入,  $x_{c-i}^H, y_{c-i}^H$  表示隐层第  $i$  节点的输入和输出,  $w_{c-ij}^{OH}, w_{c-ij}^{HI}$  分别表示隐层到输出层和输入层到隐层的权值。略去各节点的阈值参数, 则 NNC 的输入-输出映射关系为:

$$x_{c-i}^H = \sum_{j=1}^{N_c^I} (w_{c-ij}^{HI} x_{c-j}^I) \quad (4.24)$$

$$y_{c-i}^H = \sigma(x_{c-i}^H) \quad (4.25)$$

$$u_n = \sum_{i=1}^{N_c^H} (w_{c-i}^{OH} y_{c-i}^H) \quad (4.26)$$

其中

$$\sigma(x) = \frac{1 - e^2}{1 + e^{x_0}}$$

## 2. NNC 的训练

在图 4-1 所示的控制结构中, NNC 的训练是通过一个并行结构训练 NNSLC 来实现的, 即 NNC 的训练就是 NNSLC 的训练。由于它独立于系统的实时控制操作, 因此, 利用 (4.23) 式的改进形式来设计 NNSLC, 即用模型 PNNM 的输出来代替系统的实际输出, 则 NNSLC 可描述为:

$$u_{pm}(k) = NN_g(X_{up}(k), W_c) \quad (4.27)$$

其中

$$X_{up}(k) = [r(k+1), y_{pm}(k), \dots, y_{pm}(k-n_y+1), \\ u_{pm}(k-1), \dots, u_{pm}(k-n_u+1)]^T。$$

NNSLC 的训练就是调整权参数  $W_c$ , 并产生一个控制输入, 使 PNNM 的输出逼近其参考输入。PNNM 的输出可由 (4.20) 式直接得到

$$y_{pm}(k+1) = NN_f(X_{pm}(k), W_m) \quad (4.28)$$

其中

$$X_{pm}(k) = [y_{pm}(k), \dots, y_{pm}(k-n_y+1); \\ u_{pm}(k), \dots, u_{pm}(k-n_u+1)]^T。$$

通常, 对一个未知系统及给定参考输入来说, 理想的控制输入是难以预知的。因此, NNSLC 的训练信号采用参考信号与模型输出信号的偏差。训练时, 误差信号通过 PNNM 反向传播至系统的逆模型 NNSLC。在传播过程中, 仅仅是 NNSLC 的权参数  $W_c$  被调整。训练结束后, 可实现从逆模型到前馈 PNNM 的恒等映射。

由于系统是时变不确定的, 代表系统前馈动力学的 ANN 不断处于动态自适应调整中。因此, 表示系统逆动力学的 NNSLC 也相应地在每一采样周期训练一次。这样, 训练目标函数可定义为

$$E_c = \frac{1}{2} (y_{pm}(k+1) - r(k+1))^2 \quad (4.29)$$

则 NNSLC 输出节点的等效误差为上述指标对控制输入的灵敏度:

$$\delta_{u_{pm}} = \frac{\partial E_c}{\partial u_{pm}(k)} = \frac{\partial E_c}{\partial y_{pm}(k+1)} \cdot \frac{\partial y_{pm}(k+1)}{\partial u_{pm}(k)} \\ = (y_{pm}(k+1) - r(k+1)) \frac{\partial y_{pm}(k+1)}{\partial u_{pm}(k)} \quad (4.30)$$

其中  $\partial y_{pm}(k+1)/\partial u_{pm}(k)$  可直接由 ANN 的方程 (4.9)~(4.11) 经过变形获得

$$\frac{\partial y_{pm}(k+1)}{\partial u_{pm}(k)} = \sum_{i=1}^{N_m} \frac{\partial y_{pm}(k+1)}{\partial u_{pm}^H(i)} \cdot \frac{\partial y_{pm}^H(i)}{\partial x_{pm}^H(i)} \cdot \frac{\partial x_{pm}^H(i)}{\partial u_{pm}^H(k)} \\ \approx \sum_{i=1}^{N_m} w_{m-i}^{OH}(k) \cdot \sigma'(x_{pm}^H(i)) \cdot w_{m-i}^{HI}(k) \quad (4.31)$$

这样,利用 GCABP 算法,就可以对 NNSLC 进行训练了。权值修正公式为:

$$\Delta w_{c-i}^{OH}(k+1) = -\eta_c \delta_{u_{pn}}(k) y_{c-i}^H(k) + \alpha_c \Delta w_{c-i}^{OH}(k) \quad (4.32)$$

$$\Delta w_{c-j}^{HI}(k+1) = -\eta_c \delta_{c-i}^H(k) x_{c-j}^I(k) + \alpha_c \Delta w_{c-j}^{HI}(k) \quad (4.33)$$

$$\delta_{u_{pn}}(k) = (y_{pn}(k+1) - r(k+1)) \sum_{i=1}^{N_m^H} w_{m-i}^{OH}(k) \sigma'(x_{pn-i}^H(k)) w_{m-i}^{HI}(k) \quad (4.34)$$

$$\delta_{c-i}^H(k) = \sigma'(x_{c-i}^H(k)) \delta_{u_{pn}}(k) w_{c-i}^{OH}(k) \quad (4.35)$$

$$\eta_c = \lambda_c E_c^\mu / \|\nabla_{W_c} E_c\|^2 \quad (4.36)$$

$$\|\nabla_{W_c} E_c\|^2 = \sum_{i=1}^{N_m^H} (\delta_{u_{pn}}(k))^2 (y_{c-i}^H(k))^2 + \sum_{i=1}^{N_m^H} \sum_{j=1}^{N_c^I} (\delta_{c-i}^H(k))^2 (x_{c-j}^I(k))^2 \quad (4.37)$$

$$\lambda_c = \lambda_{c0} / (1 + E_c) \quad (4.38)$$

其中  $\lambda_{c0}$  为 NNSLC 的初始学习增益;  $\alpha_c$  是动量因子;  $0 < \mu_c < 1$ 。

随着  $W_c$  的调整,当 PNNM 的输出跟踪误差收敛到一给定精度时, NNSLC 的训练暂告结束。此时,我们认为, NNSLC 已能很好地代表模型 PNNM 的逆。

#### 4.3.4 运行监控器

运行监控器的作用是对系统的控制品质进行评估,当系统的控制品质下降到一定程度时,它将通过并行自学习结构训练好的 NNSLC 的参数切换到实时控制器 NNC,使系统输出跟踪参考输入。

为满足实时性要求,对不同的对象,控制品质的评估有不同的准则。本文主要考查跟踪误差。对简单或低速响应系统,采用 IATE 积分准则<sup>[183]</sup>

$$A = \int_0^t |e(k)| dk \quad (4.39)$$

这时,系统每经过一个或几个响应周期,对控制参数作一次调整。这种方法对系统不定性带来的误差不能立即作出反应。

对复杂而快速响应系统,采用瞬态误差评定准则

$$A = |e(k)| < \epsilon \quad (4.40)$$

其中  $\epsilon$  通常取为系统的稳态跟踪精度。根据这一准则,系统在每一采样周期,都对控制参数作一次调整,从而对不定性带来的误差作出迅速反应。这样,根据系统的复杂程度和响应快慢,选取不同准则,就可以灵活地确定控制参数的调整频度。一方面,可以确保系统高精度跟踪控制的需要;另一方面,可在保证系统性能指标的基础上,避免控制参数不必要的频繁修正。

#### 4.3.5 鲁棒控制器(RC)

上述控制方法成功与否在很大程度上取决于 ANNM 的辨识精度和 NNC 的学习情况。要使神经网络具有准确跟踪被控对象动态特性的能力,在对系统实施每拍控制之前, ANNM 和 NNC 必须进行一次或多次在线训练,直至收敛状态。这势必影响控制的实时性。因此,引入鲁棒反馈控制器 RC,当 ANNM 有偏差,或学习尚未完全收敛时(在控制

初期,这一情况较为严重),鲁棒控制器 RC 根据系统的输出跟踪误差,产生一反馈控制信号,保证控制过程的连续性和闭环系统的稳定性,同时为 NN 的训练提供实时数据;当 ANNM 已经收敛而系统受到外干扰的影响时,鲁棒控制器还可以通过鲁棒因子,引入补偿控制,消除外干扰对控制系统的影响。因此,整个控制系统不仅具有很好的跟踪性能,而且具有很好的鲁棒特性。这里,鲁棒控制器 RC 设计为一固定增益比例控制器,其控制方程为:

$$u_r(k) = K_r e_r(k) \quad (4.41)$$

其中  $K_r$  为控制器增益; $e_r(k)$  为系统的输出跟踪误差。

#### 4.3.6 NNPSLRATC 的算法实现及其特点

综上所述,NNPSLRATC 的实现步骤如下:

首先完成初始化 ANNM、NNC 的结构、参数及各种训练参数:  $K_r$ 、 $\lambda_{n0}$ 、 $\mu_m$ 、 $\alpha_m$ 、 $\lambda_{r0}$ 、 $\mu_c$ 、 $\alpha_c$ 、 $\tau$ 、 $\epsilon_m$ 、 $\epsilon_r$ 、 $\epsilon_{pm}$ 。

- (1) 在时刻  $k$ , 采样  $y(k)$ ,  $r(k)$ 。
- (2) 构造 ANNM 的输入向量  $X(k-1)$ , 按(4.8)式求  $y_m(k)$ , 并计算 ANNM 的输出偏差  $e_m(k) = y_m(k) - y(k)$ 。
- (3) 若  $e_m(k) > \epsilon_m$ , 按式(4.13)~(4.19)修正  $(k-1)$  时刻 ANNM 的权值, 否则, 继续下一步。
- (4) 将 ANNM 的网络参数传给并行自学习结构中的 PNNM。
- (5) 计算系统的输出偏差  $e_r(k) = r(k) - y(k)$ , 并求得鲁棒控制器 RC 的输出  $u_r(k) = K_r e_r(k)$ 。
- (6) 若  $e_r(k) > \epsilon_r$ , 用 NNSLC 的权值替代 NNC 的权值, 否则继续。
- (7) 构造 NNC 的输入向量  $X_{un}(k)$ , 并按(4.23)式计算其输出  $u_n(k)$ 。
- (8) 按式(4.5)~(4.7)计算控制器输出  $u(k)$ , 并同时送入被控对象和 ANNM, 产生下一步输出  $y(k+1)$ 。
- (9) 令  $k = k+1$ , 对  $\{y(k)\}$ ,  $\{u(k)\}$  进行移位处理, 返回步骤(1)。

以下过程由并行自学习结构同期完成:

- (1') 在时刻  $k$ , 采样得到  $r(k+1)$ ,  $y_{pm}(k)$ 。
- (2') 获取 ANNM 的网络参数, 产生  $k$  时刻的 PNNM 网络。
- (3') 构造 NNSLC 的输入向量  $X_{up}(k)$ , 按(4.27)式计算其输出  $u_{pm}(k)$ 。
- (4') 构造 PNNM 的输入向量  $X_{pm}(k)$ , 按(4.28)式计算其输出  $y_{pm}(k+1)$ 。
- (5') 计算 PNNM 的输出偏差  $e_{pm}(k) = y_{pm}(k+1) - r(k+1)$ 。
- (6') 若  $e_{pm}(k) > \epsilon_{pm}$ , 按式(4.32)~(4.38)修正 NNSLC 的网络参数, 否则继续。
- (7') 若有权值更新请求, 传送 NNSLC 的网络权值至 NNC。
- (8') 令  $k = k+1$ , 对  $\{y_{pm}(k)\}$ ,  $\{u_{pm}(k)\}$  进行移位处理, 返回步骤(1')。

下面对本节提出的神经网络并行自学习鲁棒自适应控制器作几点讨论。

**讨论 4.1** ANNM 和 NNC 不经过事先训练, 不影响系统的跟踪控制效果。在本控制结构中, 神经网络的引入使得系统的实时控制部分和参数自学习部分均相当于一个直接自适应反馈系统。由 2.6 节的结论, 神经网络的学习是一动态渐近收敛过程, 当  $k \rightarrow \infty$

时,可做到网络对系统动力学或逆动力学的高精度逼近。4.6 节的实验研究亦发现,对一时变不确定系统,采用一事先训练好的神经网络除了在初始响应阶段上升时间上有明显优势外,其控制效果并不比一个初始权很小而随机赋值的网络具有更好的收敛性和稳态跟踪精度。

**讨论 4.2** 在并行自学习控制结构中,当 ANNM 的精度较差时,由 NNC 逼近的系统逆动力学将存在有偏问题,势必影响系统的控制行为。但由于实时控制器中鲁棒因子的作用,使依据 ANNM 设计的 NNC 的作用大大削弱,而增强了鲁棒控制器 RC 的作用,从而不会对控制系统的稳定性构成威胁。

**讨论 4.3** 当系统受到干扰造成 ANNM 不准确,或 NNC 的训练偶尔未进入收敛状态时,系统也将产生有偏的控制输入。但由于 ANNM 的在线辨识和 NNC 的在线学习过程在每一采样周期连续不断地重复进行,使得这种有偏的控制输入信号将不会持续下去。因此,系统的跟踪性能将不会因为偶然产生的有偏控制而受到很大影响。

**讨论 4.4** NNC 的训练过程实际上就是对方程(4.23)求解  $u(t)$  的过程。当系统的逆不惟一时,必然存在多个解,使系统满足控制要求。由于控制信号在对系统实施控制时,实际上是其控制能量在起作用。因此,我们通常选择最小能量控制信号,对系统实施控制。为此,在训练 NNC 时,网络的初始权置为很小的随机值,使 NNC 的输出从很小的值开始增长,以便收敛到系统可能具有的多个解的最小解上<sup>[178]</sup>。

**讨论 4.5** 实时性差是神经网络控制通常存在的问题。这是由于通过在线辨识得到的 ANNM,反映的是系统的输入-输出映射特性,而非传统的数学模型,因此控制器的设计也不能用传统的方法进行,需要通过学习来完成。对复杂系统,难免存在运算量大、控制参数调整耗时长等问题。本节采用的是一个多处理器并行工作的控制结构,控制参数的调整不占用实时控制的时间;且由于运行监控器的协调作用,可针对具体对象,灵活地改变控制参数的调整频度,从而满足控制系统的实时性要求。

由上述分析可知,NNPSLRATC 方法具有如下特点:

① 系统的控制信号是由 NNC 和一个鲁棒控制器共同给出的,在 NNC 训练初期,鲁棒控制器 RC 可保证对系统实施稳定的反馈控制,便于神经网络的在线学习。当 NNC 逼近对象的逆动态时,鲁棒因子的作用使 NNC 逐步替代鲁棒控制器 RC,对系统实施高精度的跟踪控制。在这一过程中,RC 的鲁棒性逐渐削弱,控制器的适应能力逐渐增强。因此,从一定意义上说,本章提出的方法可称之为神经网络变鲁棒自适应控制方法。

② 神经网络控制系统是由两个并行工作的处理器来实现的,有利于改善复杂系统神经网络控制的实时性。NNC 的训练是通过并行自学习结构中 NNSLC 的训练来实现的,这是一个虚拟训练过程<sup>[186]</sup>。在 NNSLC 的训练中,无须知道系统的测量数据,即可独立地对控制参数进行预测调整。NNSLC 的学习过程与系统的实时控制过程是并行进行的。由于 NNC 与 NNSLC 的结构与参数完全一样,当后者学习完毕,前者也就自然完成了对系统逆的逼近。因此,这种学习结构在控制效果上相当于省去了 NNC 的学习时间,增强实时性。

③ 在并行自学习结构中,用于 NNSLC 训练的误差信号是参考输入与预测模型 PN-NNM 输出的偏差,而没有用到实际系统的输出,有利于对有噪声系统的跟踪控制。

④ NNC 对系统逆动态的逼近是依据在线辨识得到的 ANNM 进行的,因此,当系统

的前馈映射不是一对一时,也能通过并行自学习结构得到一个特定的逆,使系统满足控制要求。

⑤ 控制系统中,ANNM 和 NNC 的设计仅依赖于少量定性的先验知识,且无需经过事先训练,可根据实时输入输出测量信息进行自适应跟踪辨识和在线动态设计,具有较大的适用范围。

#### 4.4 神经网络并行自学习鲁棒自适应控制系统的稳定性

稳定性是控制系统最基本和最重要的性质之一。一个能正常运行的系统,首先必须稳定。只有在保证稳定的前提下,追求优良的性能指标才是可行的和有意义的。在基于数学模型的常规控制理论中,系统的稳定性分析已有较成熟的理论和方法。但对于神经网络控制系统而言,由于神经网络结构的复杂非线性,以及控制对象、控制环境的不确定性,使得这类系统的稳定性分析变得很困难。所以,在神经网络控制领域,涉及稳定性分析的研究工作仍显得较少<sup>[66~68]</sup>,且多数是针对具体的控制结构进行的<sup>[71,175,187~189]</sup>。

为分析本章提出的神经网络并行自学习鲁棒自适应跟踪控制系统的稳定性,先给出以下假设:

**假设 4.1** 对(4.1)式所示系统,若  $\forall u \in \Omega_u, y \in \Omega_y$ , 当  $u \neq 0, y \neq 0$  时,有下式成立

$$\frac{\partial y}{\partial u} \neq 0 \quad (4.42)$$

即系统(4.1)是可控的。

**假设 4.2** 对  $k \in [0, +\infty]$ , 系统的参考输入  $r(k)$  是有界的,即

$$|r(k)| < M \quad (4.43)$$

##### 4.4.1 并行自学习系统的反馈稳定性

**定义 4.1** 设 NNC 的输出及其期望输出分别为  $u_n(k)$  和  $u_{ref}(k)$ , 则 NNC 的输出等效误差为

$$S(k) = u_n(k) - u_{ref}(k) \quad (4.44)$$

由定理 2.5 和定理 3.1 可知,若系统是 BIBO 的,那么对  $\forall u \in \Omega_u$ , ANN 的训练总是收敛的。则对并行自学习系统的稳定性,有如下定理:

**定理 4.1** 在假设 4.1 和 4.2 的条件下,利用神经网络自适应学习规则(4.32)~(4.38)训练 NNC 的权值,可使并行自学习系统的输出跟踪误差达到最优,即  $\forall \epsilon > 0, \exists N > 0$ , 使

$$\lim_{i \rightarrow \infty} \|y_m^i(k) - r(k)\| \leq \epsilon \quad (4.45)$$

证明:为叙述方便,并行自学习系统中的 NNSLC 和 PNNM 直接用 NNC 和 ANN 来描述。

假定在时刻  $k$ , ANN 已经收敛, NNC 第  $i$  次学习后的输出为  $u_n^i(k)$ 。

由定理 2.5 可知,若定义 NNC 的训练误差函数为

$$E_c(k, i) = \frac{1}{2} S_i^2(k) = \frac{1}{2} (u_n^i(k) - u_{ref}(k))^2 \quad (4.46)$$

则利用神经网络自学习规则(4.32)~(4.38)式训练 NNC 时,必存在一组网络权值  $W_i(k)$ ,使得对任意给定的  $\varepsilon_i \geq 0$  和由(4.24)~(4.26)式定义的 NNC,  $\exists N > 0$ ,使下式成立:

$$\lim_{i \rightarrow \infty} \|S_i(k)\| = \lim_{i \rightarrow \infty} \|u_n^i(k) - u_{ref}(k)\| \leq \varepsilon_i \quad (4.47)$$

由(4.30)式知,

$$S_i(k) = \delta u_n^i(k) = (y_m^i(k+1) - r(k+1)) \frac{\partial y_m^i(k+1)}{\partial u_n^i(k)} \quad (4.48)$$

则

$$\lim_{i \rightarrow \infty} \left\| (y_m^i(k+1) - r(k+1)) \frac{\partial y_m^i(k+1)}{\partial u_n^i(k)} \right\| \leq \varepsilon_i \quad (4.49)$$

即

$$\lim_{i \rightarrow \infty} \left\| (y_m^i(k+1) - r(k+1)) \right\| \cdot \left\| \frac{\partial y_m^i(k+1)}{\partial u_n^i(k)} \right\| \leq \varepsilon_i \quad (4.50)$$

根据假设 4.1,并考虑到  $t$  时刻 ANNM 已经收敛,上式左边乘积的第二项为一非零常数。故

$$\lim_{i \rightarrow \infty} \left\| (y_m^i(k+1) - r(k+1)) \right\| \leq \varepsilon \quad (4.51)$$

其中

$$\varepsilon = \varepsilon_i / \left\| \frac{\partial y_m^i(k+1)}{\partial u_n^i(k)} \right\|$$

证毕。

#### 4.4.2 鲁棒自适应跟踪系统的稳定性

**引理 4.1** 对对称 Sigmoid 神经元激活函数,  $\forall x \in R, \exists C > 0$ ,使得

$$|\sigma(x)| \leq C |x| \quad (4.52)$$

证明:由于  $\sigma(x) = \frac{1-e^{-x}}{1+e^{-x}}$  是 Lipschitz 的<sup>[190]</sup>,因此,  $\forall x_1, x_2 \in R$ ,必存在一常数  $C > 0$ ,使得

$$|\sigma(x_1) - \sigma(x_2)| \leq C |x_1 - x_2| \quad (4.53)$$

即

$$|\sigma(x_1)| - |\sigma(x_2)| \leq |\sigma(x_1) - \sigma(x_2)| \leq C |x_1 - x_2| \quad (4.54)$$

令  $x_2 = 0$ ,并注意到  $\sigma(0) = 0$ ,则

$$|\sigma(x_1)| \leq C |x_1| \quad (4.55)$$

证毕。

**引理 4.2** 对(4.24)~(4.26)定义的 NNC 模型,存在一常数  $C(w)$ ,使得  $\forall X_u(t) \in R^{n+m}$ ,有下式成立

$$|u_n(k)| \leq C(w) \|X_u(k)\| \quad (4.56)$$

证明:由引理 4.1 和 NNC 方程(4.24)~(4.26)可得

$$\begin{aligned}
|u_n(k)| &\leq \sum_{i=1}^{N_c^H} |w_{c-i}^{OH}(k)| \cdot \left| \sigma \left( \sum_{j=1}^{N_c^I} w_{c-i}^{HI}(k) x_{c-j}^I(k) \right) \right| \\
&\leq \sum_{i=1}^{N_c^H} |w_{c-i}^{OH}(k)| \cdot C \left| \sum_{j=1}^{N_c^I} w_{c-i}^{HI}(k) x_{c-j}^I(k) \right| \\
&\leq \sum_{i=1}^{N_c^H} |w_{c-i}^{OH}(k)| \cdot C \left\| \tilde{W}_{c-i}^{HI}(k) \right\| \cdot \left\| X_u(k) \right\| \\
&= C(w) \left\| X_u(k) \right\|
\end{aligned} \tag{4.57}$$

其中:

$$\tilde{W}_{c-i}^{HI}(k) = [w_{c-i}^{HI_{i1}}(k), w_{c-i}^{HI_{i2}}(k), \dots, w_{c-i}^{HI_{iN_c^I}}(k)]^T;$$

$$C(w) = \sum_{i=1}^{N_c^H} |w_{c-i}^{OH}(k)| \cdot C \left\| \tilde{W}_{c-i}^{HI}(k) \right\|。$$

证毕。

**定理4.2** 对(4.1)式所示系统,它满足假设 4.1 和 4.2,若采用(4.5)式表示的神经网络自适应控制律进行控制,则系统的输出能渐近地跟踪任意给定的参考输入。

证明:神经网络变鲁棒自适应控制系统的工作过程包括两个阶段:暂态调节阶段和稳态跟踪阶段。

在稳态跟踪阶段,神经网络的学习暂告结束。此时,ANNM 已能很好地反映系统的动力学。此时,模型的跟踪辨识误差  $E_m \approx 0$ ,控制系统的鲁棒因子  $\gamma \approx 1$ ,系统的控制律由(4.5)式变为

$$u(k) \approx u_n(k) \tag{4.58}$$

这时,实时变鲁棒自适应 NNCS 在结构上等价于并行自学习系统。其输出跟踪稳定性可直接有定理 4.1 给出。

下面只需证明在暂态调节阶段,控制器的输出有界即可。

在暂态调节阶段,ANNM 的学习尚未完全收敛。控制律由(4.5)式决定。在控制初期,  $E_m$  较大,对系统控制起决定作用的是鲁棒控制器 RC,NNC 的输出对系统的影响很小。因此,由假设 4.2 可知,系统的输出误差  $e_r(k)$  是有界的。即  $\forall r(k) \in \Omega_y, \exists M_{ur} \geq 0$ ,使得

$$\left\| e_r(k) \right\| \leq M_{ur} \tag{4.59}$$

进而可推得 NNC 的输入向量  $X_u(k)$  有界。

另外,由定理 4.1 可知,NNC 的学习是一致收敛的。因此,其权值  $W_c$  是一致有界的。故由引理 4.2 可知,NNC 的输出  $u_n(k)$  有界,即

$$\left\| u_n(k) \right\| \leq M_{un} \tag{4.60}$$

其中  $M_{un} \geq 0$  为常数。则由(4.5)式得:

$$\left\| u(k) \right\| = \left\| \gamma u_n(k) + (1 - \gamma) u_r(k) \right\|$$



$$\begin{aligned} &\leq \left\| \gamma u_n(k) \right\| + \left| K_r(1-\gamma) \right| \cdot \left\| e_r(k) \right\| \\ &\leq \gamma M_{u_n} + K_r(1-\gamma) M_{u_r} \end{aligned} \quad (4.61)$$

其中:鲁棒因子  $\gamma \in [0,1]$ ;  $K_r$  为鲁棒控制器的反馈系数,是一确定常数。因此,由(4.61)式可知,神经网络实时变鲁棒自适应控制器的输出是有界的。故系统是输入输出有界的。

由以上分析,系统在稳态跟踪阶段渐近收敛,在暂态调节阶段输入输出有界,故系统在控制过程中是渐近稳定的。

证毕。

## 4.5 仿真研究

### 4.5.1 控制对象

控制对象为电液力伺服加载系统,这是一个典型的阀控制液压缸系统。该系统是一个非线性时变系统。液压机构中的一些软参量具有一定的随机性;被试件的参数如质量、刚度等可在大范围内改变;在加载过程中,系统受到的外干扰和试件因疲劳破坏而造成的参数变化等都具有严重不确定性,难以精确建模。其结构如图 4-3 所示。

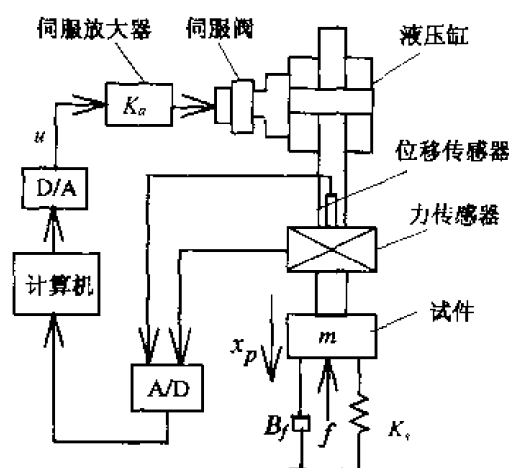


图 4-3 电液力伺服加载系统示意图

系统的支配方程由下式决定

$$m \ddot{x}_p + B_f \dot{x}_p + K_s x_p + f = A_e P_l \quad (4.62)$$

$$\frac{V_t}{4\beta_e} \dot{P}_l + A_e \dot{x}_p + c_l P_l = K_v \sqrt{(P_s - \text{sgn}(u)P_l)} \cdot u \quad (4.63)$$

$$F_g = A_e P_l \quad (4.64)$$

其中:  $K_v = c_d K_a K_{sv} \omega / \sqrt{\rho}$ ;  $x_p$  为活塞位移;  $m$  为负载质量;  $B_f$  为负载阻尼系数;  $K_s$  为负载弹簧刚度;  $f$  为外干扰力;  $A_e$  为油缸的有效截面积;  $\beta_e$  为油的弹性模量;  $V_t$  为液压油腔的总体积;  $c_l$  为总泄漏系数;  $P_s$  为供油压力;  $P_l$  为负载压力;  $K_a$  为伺服放大器的增益;  $K_{sv}$  为电液伺服阀的增益;  $F_g$  为液压缸的输出力;  $u$  为电液伺服阀的控制输入信号。式中各

物理参数如表 4-1 所示。

控制的目的是通过对系统施加适当的控制量,使其对试验件实施高精度的力伺服疲劳加载试验。要求控制系统具有快速性、无超调、无静差、抗干扰能力强等特点。

表 4-1 电液力伺服加载系统的主要参数

物理量	参数值	物理量	参数值	物理量	参数值
$\beta_e$	700MPa	$V_f$	$1.2535 \times 10^{-3} \text{m}^3$	$\rho$	$860 \text{kg/m}^3$
$A_e$	$6.2675 \times 10^{-3} \text{m}^2$	$K_a$	$2.647 \times 10^{-6} \text{m/A}$	$P_s$	15MPa
$m$	300kg	$c_f$	$4.7 \times 10^{-13} \text{m}^5/\text{Ns}$	$K_j$	$3.5 \times 10^6 \text{N/m}$

本节根据 4.3 节的设计思想,构造一个神经网络并行自学习变鲁棒自适应控制器,来实现上述控制任务,并验证控制系统的鲁棒性和适应性。

### 1. ANNM 的构造

电液力控制系统可看作一阶或二阶惯性系统,且是一慢时变过程。因此 ANNM 采用输入层为 4 个神经元、输出层为 1 个神经元的三层前馈网络。隐层单元数由仿真试验确定,考虑 Lippmann 准则<sup>[191]</sup>,本例中发现 5~8 个隐单元均能取得较好的效果,仿真中选取 6 个。由于本结构中,ANNM 和 NNC 都是在线动态调整的,而非在整个输入空间中概括系统的全部特性,因此不必将 ANNM 的结构选得过于复杂庞大。不失一般性,网络的初始权值在  $(-0.1, 0.1)$  区间内随机选取,其他训练参数分别设置为  $\lambda_{m0} = 0.65$ 、 $\mu_m = 0.5$ 、 $\alpha_m = 0.75$ 、 $\epsilon_m = 10^{-5}$ 。

### 2. NNC 的构造

NNC 的结构选为  $3 \times 3 \times 1$ ,其中输入层包括系统的上一拍输出和控制输入信息以及下一拍参考输入信息。网络的初始权值在  $(-0.1, 0.1)$  区间内随机选取,其他训练参数分别为  $\lambda_{c0} = 0.35$ 、 $\mu_c = 0.5$ 、 $\alpha_c = 0.65$ 、 $\epsilon_c = \epsilon_{pm} = 10^{-3}$ 。

### 3. RC 的构造

鲁棒控制器 RC 的比例系数取为  $K_r = 1$ ,鲁棒因子的变鲁棒系数取为  $\tau = 0.5$ 。

假定系统对 ANNM 和 NNC 来说均是未知的,即 ANNM 和 NNC 均不经过事先训练,直接根据实时测量信息,在线学习系统动力学,并对系统实施控制。

另外,由于神经元采用的 sigmoid 激活函数的取值范围为  $(-1, 1)$ ,而电液力伺服加载系统的被控量往往很大,因此,为确保控制精度,在参考信号和反馈信号送入控制器进行运算之前,应进行归一化处理。

## 4.5.2 仿真结果

本节对以下四种情况进行了研究。

### 1. 理想情况下对未知系统的跟踪控制

理想情况下的跟踪控制用来测试神经网络的学习性能。系统对方波的跟踪曲线如图 4-4 所示。可以看出,控制器在对象未知的情况下,经过有限次在线学习后,即可实现对系统的跟踪控制。表明 ANNM 和 NNC 具有良好的自学习和自适应能力。



图 4-4 对未知系统的跟踪控制结果

### 2. 存在外干扰时的跟踪控制

图 4-5 示出系统在  $t \in [1.1, 2.6]$ s 时存在  $f = 2000$ N 的外力干扰时的跟踪响应。由图可知,系统的输出响应在受到外力干扰后,能很快返回到其理想的轨迹附近,表明控制器对外部干扰具有很强的鲁棒性。




图 4-5 存在外干扰时的跟踪控制结果

### 3. 参数时变条件下的跟踪控制

图 4-6 给出  $t > 1.0$ s 时负载质量增加两倍、负载刚度由  $3500 \text{ kN/m}$  降为  $2000 \text{ kN/m}$ 、油的弹性模量由  $700 \text{ MPa}$  变为  $1400 \text{ MPa}$  时系统的跟踪响应。由图可知,系统能克服参数时变这一不确定干扰的影响,保持良好的跟踪性能,表明控制器对系统的不确定性具有良好的自适应能力。




图 4-6 参数时变时的跟踪控制结果

#### 4. 存在测量噪声时的跟踪控制

图 4-7 示出存在信噪比为 15% 的随机测量噪声、且  $t \geq 2.2\text{s}$  出现  $f=2000\text{N}$  的外力干扰时系统的响应。可以看出,控制器仍然能平稳地学习系统的特性,跟踪系统的输出,并对噪声干扰具有较强的鲁棒性。




图 4-7 存在测量噪声时的跟踪控制结果

## 4.6 实验研究

### 4.6.1 控制对象

实验研究对象为一电液位移伺服系统。被控对象是“汽车板簧-小车”系统,实验装置如图 4-8 所示。其中液压缸的额定载荷为 100kN,小车质量约为 250kg,板簧具有严重非线性<sup>[137]</sup>。这里通过板簧引入一个大小可变的干扰外力,用来说明系统的不确定性。

控制系统框图如图 4-9 所示。该系统是一个双环控制结构,其中内环的作用有二:一是改善被控对象的特性,提高系统的响应速度;二是在控制系统启动前,构成闭环回路,使电液位移伺服系统进入一个稳定的初始状态,以防止电液伺服阀因正开口而造成的系统失稳。

为研究系统的已知信息对神经网络并行自学习鲁棒自适应跟踪控制器控制效果的影

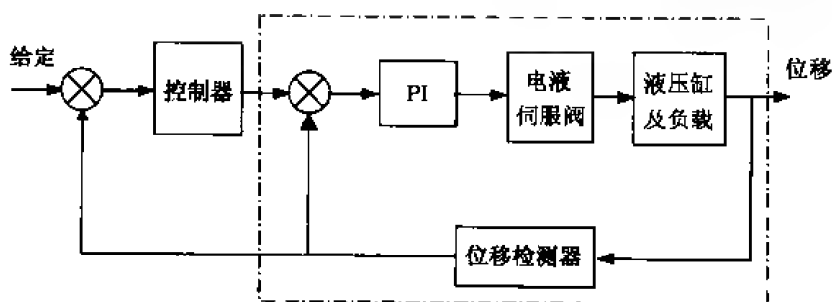



图 4-9 位移伺服系统原理框图

响,本节对图 4-8 所示的电液位移伺服加载系统进行初始辨识建模。其中非线性板簧装置处于松弛状态,即将其作为初始辨识模型的未建模动态。忽略系统中一些非线性因素和外力干扰的影响,并在工作点附近对系统(4.62)、(4.63)式进行增量线性化处理,得到系统的线性传递函数为

$$G(s) = \frac{Y_p(s)}{U(s)} = \frac{K_1}{(s + K_2) \left( \frac{s^2}{\omega^2} + \frac{2\zeta}{\omega}s + 1 \right)} \quad (4.65)$$

考虑液压缸的工作频率小于 25Hz,在此频率范围内,系统可看着是一个二阶振荡环节。通过实验辨识,其传递函数为<sup>[137]</sup>

$$G(s) = \frac{Y_p(s)}{U(s)} = \frac{5}{\frac{s^2}{\omega_n^2} + \frac{2\zeta}{\omega_n}s + 1} \quad (4.66)$$

其中:  $\omega_n = 100.5 \text{ rad/s}$ ,  $\zeta = 0.12$ 。需要说明, (4.66) 式并未考虑汽车板簧的影响,仅将其作为系统的未建模动态。

因受硬件资源的限制, NNPSLRATC 和试验波形发生器采用一台 NEC433 计算机实

现<sup>[192]</sup>。这样,在 4.3.6 节的 NNPSLRATC 的算法实现过程中,NNC 的训练应紧接着 ANNM 的训练步骤之后进行。A/D、D/A 采用 16 位 AX5621 板,采用中断方式工作。输入输出信号范围为 $(-10\text{V}, 10\text{V})$ 。

根据以上的辨识结果,该位移伺服系统是一个二阶系统。故 ANNM、NNC、RC 的构造,网络的初始权值及训练参数设置均与 4.5 节相同。

#### 4.6.2 控制结果

本节研究了以下两种控制情况。

##### 1. 系统模型未知时的控制结果

假定模型(4.66)式未知,ANNM 和 NNC 均不经事先训练,根据实时测量信息,在线学习系统动态和逆动态。

图 4-10 给出了位移控制加载的跟踪响应结果。可以看出,控制器能平滑地跟踪学习系统的特性,并对其实施良好的控制。在初始阶段,控制器的学习还不够完善,响应是一渐近自适应收敛过程。经过有限次在线学习后,系统可得到有效的控制,没有出现超调和振荡,动态精度可达 3% 以内,并对板簧引入的干扰具有良好的鲁棒性。




图 4-10 模型未知时的控制结果

##### 2. 初始模型已知时的控制结果

假定模型(4.66)式已知,并将其作为系统的初始模型对 ANNM 进行离线训练,而将板簧的影响视为系统的未建模动态。训练数据是通过对该模型施加 $[-10\text{V}, 10\text{V}]$ 的随机输入信号产生的输入-输出样本对 100 个,模型的初始权值随机选取。经过 5000 次训练后,应用 ANNM 对系统进行控制。

图 4-11 给出了正弦波位移伺服加载控制曲线。可以看出,神经网络并行自适应跟踪控制器能克服未建模动态的影响,具有良好的跟踪效果,控制曲线没有出现超调和振荡。比较图 4-10 和图 4-11,可以发现,初始模型已知时的控制结果在收敛时间上,比系统模型未知时具有明显的优势,但控制精度上,二者几乎没有差别。这一点正好说明了采用本章提出的控制方法,神经网络是否经过事先训练,对控制的收敛性和稳态

跟踪精度影响不大。




图 4-11 初始模型已知时的控制结果

## 4.7 本章小结

本章针对工业系统模型未知情况,研究了一类不确定非线性系统的神经网络在线自学习控制问题。提出了一种神经网络并行自学习鲁棒自适应跟踪控制结构,对 ANNM 的在线学习、NNC 的在线设计与实现进行了深入研究,并证明了设计的闭环系统在其变量一致有界的意义上是全局稳定的。最后,结合具有典型非线性和时变特点的电液伺服系统,从仿真和实验两方面证实了所提出的神经网络控制结构的有效性和实用价值。

该方法通过引入鲁棒因子,将神经网络控制与传统控制方法有机结合起来,实现了对象模型的在线自适应跟踪辨识和控制器的在线动态设计;NNC 采用并行结构进行训练,其参数调整独立于系统的实时控制,有效地解决了神经网络控制方法通常存在的实时性差的问题,使复杂系统的在线学习控制成为可能。为未知不确定非线性系统的智能控制提供了一条有效的新途径。

## 第五章 模型参考神经网络直接自适应控制

### 5.1 引言

随着神经网络研究的深入,神经网络在控制中的应用已从开始的仿真研究,逐步走向了应用研究<sup>[69,184,185]</sup>。在诸多神经网络控制方式中,虽然直接控制还不能从理论上直接得到基于未知非线性系统输出误差的网络权值调整方法,但是,“简单是真的印记”这句拉丁格言一直影响着人们在工程上的选择。因此,神经网络直接自适应控制以其结构简单、算法简洁、工程上易于理解而倍受人们的重视<sup>[193-195]</sup>。

在直接神经网络控制中,应用较广的有两种方式,直接逆控制和模型参考神经网络直接自适应控制。直接逆控制是利用神经网络的函数逼近能力,来近似实现系统的逆动力学模型,然后与被控系统串联,以使系统的期望输出(即网络输入)与实际对象输出之间实现恒等映射。该方法的可行性在相当程度上取决于逆模型的准确程度,为此需要大量的数据进行辨识。另外,如果系统的逆不存在时,该方法将难以奏效。

模型参考神经网络直接自适应控制结构如图 5-1 所示。该方法提供了一个期望的参考模型,要求系统输出能够跟随参考模型的输出。这种控制方式是神经网络与线性系统的模型参考自适应控制相结合的一种控制策略,其不足之处在于用误差反传学习算法调整神经网络权值时,必须知道系统的 Jacobi 矩阵。对未知非线性系统而言,这是很困难的。但是现今的研究表明<sup>[44]</sup>,如果知道系统的大致信息,如 Jacobi 矩阵的符号信息,也能够直接构造权值调整规则。从工程角度看,要做到这一点并不难。因此神经网络直接自适应控制逐渐成为工程中比较实用的控制策略。

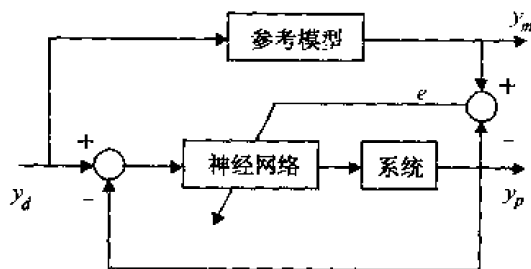


图 5-1 模型参考神经网络直接自适应控制

PID 控制因其简单易行、鲁棒性强,至今仍是应用最广也是工程界最受欢迎的控制方式。一般而言,在 PID 能够实现的控制功能的场合,人们总是优先选用 PID 控制。当然,随着控制理论的发展,PID 控制也经历着变革与发展,如由最古老的定参数线性 PID 到可针对非线性系统设计的非线性 PID 策略等<sup>[196]</sup>。其实,线性系统的自适应控制律实际上也是状态参数的 PID 线性组合,只是为了加强自适应能力,PID 参数是在线实时调整的;而目前神经网络 PID 控制只不过是神经网络学习算法来调整 PID 的参数而已。虽



然,随着控制任务的日益复杂和控制目标的日愈精细,常规的定常系数 PID 控制器正逐渐失去其昔日的丰采,但是 PID 控制器的设计思想同反馈控制理论一样,依然左右和支配着人们在进行控制器的设计时自觉和不自觉地加以运用。例如,基于 Popov 超稳定理论的自适应律设计<sup>[110]</sup>、基于 Lyapunov 稳定性设计方法、模糊控制对误差及其微分信号的利用<sup>[17]</sup>等均利用了 PID 控制的思想。

作为一种直接自适应控制器,虽然神经网络在设计时还存在一定缺陷,如初值的选取、节点选择等方面尚缺乏严格的理论指导,但由于其设计思路简单,且在一定条件下稳定性和收敛性能定性地得到保证<sup>[71,175]</sup>,因此在工程中仍取得了一些成功的应用。从这一点也可以说,目前在神经网络研究方面,应用性研究略超前于纯粹的理论研究。

在神经网络直接自适应控制 NNDAC 中,网络权值的调整相当于对控制误差的积分。正是因为该“积分”作用,NNDAC 可以做到系统阶跃响应稳态无差。在动态跟踪控制中,通常要求神经网络不但有较快的收敛速度,还要有较快的动态调节能力。理论上讲,提高控制器的收敛速度能够加快系统收敛速度,但实际上也存在神经网络虽已收敛,但控制效果并不十分理想的情况<sup>[175]</sup>。

对于一个连续的控制问题,控制目的是要求受控制对象尽快收敛到一定的误差区域,而非考查神经网络权值是否已经收敛,这是当今人们运用 NNDAC 易陷入的误区。所以,如何提高控制器的动态调节能力,在连续系统的动态跟踪控制中显得尤为重要。本章根据古典 PID 控制的精髓,提出一种新的神经网络直接自适应控制器,其网络权值由三部分组成:比例项、积分项和微分项。积分项即为传统神经网络权值部分,其作用是产生记忆,保证控制的连续性和稳态收敛精度;比例项和微分项的作用则保证了在控制误差出现时网络权值具备“瞬态”的应变能力,从而产生相应的调节控制量。微分项还具有一定的变结构控制能力,可以增强控制器的鲁棒性。

在 NNDAC 系统中,由于初始权值的选择具有盲目性,如取随机数,会造成初始控制时系统可能会产生振荡。通常采取的措施是,先采用传统控制器,如 PID 控制,对系统实施控制,神经网络控制器经过初期训练后,逐步进入控制环节,最终取代 PID 控制器<sup>[197]</sup>;或者采取离线辨识的方法,得到系统逆动力学模型,并作为 NNDAC 的初始权值模型<sup>[76]</sup>。前者的缺点是不能保证初始控制精度,后者存在逆传函辨识所需要的诸如激励信号的选择等问题。

目前,在 NNDAC 系统中,运用较多也是较为成功的是 BP 网络和动态递归 Elman 网络,以及 CMAC 网络和高阶 HONN 网络等<sup>[48]</sup>。这些都是针对非线性系统提出的网络模型,网络本身具备全局或局部的优化能力。与这些网络相比,Adaline 网络在函数逼近能力方面稍为逊色<sup>[55]</sup>,因而在非线性系统控制方面较少采用。但是,如果将该网络作为 NNDAC 控制器,并适当选择输入层,其形式和作用将相当于传统的自适应控制器。在线性系统、弱非线性系统和慢时变系统中,Adaline 网络的参数设计、稳定性分析,很存易由 Popov 或 Lyapunov 稳定性方法得到解决。相对于传统的自适应控制方式,Adaline 网络又具备较大的灵活性。因此,如果将 Adaline 与搜索能力较强的多层网络结合起来,则可能更好地发挥二者的优点。因此图 5-2 给出的混合神经网络控制方案不失为一种较佳的 NNDAC 控制方案。

本章针对离散动态系统,提出两种新的 NNDAC 设计方法:广义 PID 神经网络直接




图 5-2 混合神经网络直接自适应控制

自适应控制器和模型参考混合神经网络直接自适应控制器,从理论上分析了控制算法的收敛性,并通过数字仿真研究证明了提出的控制方法的有效性。

## 5.2 广义 PID 神经网络直接自适应控制器设计

### 5.2.1 控制器结构及控制算法

考虑系统

$$y_p(k+1) = f[y_p(k), \dots, y_p(k-n), u_p(k), \dots, u_p(k-m)] \quad (5.1)$$

其中:  $y_p(k) \in R^n$ ,  $u_p(k) \in R^m$  为系统的输出和输入;  $n$ 、 $m$  分别是系统的阶次;  $f(x)$  为未知非线性函数。设参考模型为如下的线性方程

$$y_m(k+1) = A_m y_m(k) + B_m u_m(k) \quad (5.2)$$

其中

$$A_m(z) = a_0 + a_1 z^{-1} + \dots + a_n z^{n-1}$$

$$B_m(z) = b_0 + b_1 z^{-1} + \dots + b_{m-1} z^{m-1}$$

$y_m$ 、 $u_m$  分别为参考模型的输出和输入。

为实现系统输出对模型输出的高精度跟踪,设计广义 PID 神经网络直接自适应控制结构如图 5-3 所示。其中控制器由神经网络来实现,控制率为

$$u_p(k) = NN_f(X, W) \quad (5.3)$$

其中:  $X$  为网络输入向量;  $W$  为网络权值矩阵。




图 5-3 广义 PID 神经网络直接自适应控制结构

定义系统的跟随误差为

$$e(k) = y_m(k) - y_p(k) \quad (5.4)$$

并定义性能指标为

$$J = \frac{1}{2} \sum (y_m(k) - y_p(k))^2 \quad (5.5)$$

控制率的学习就是按性能指标的负梯度方向调整神经网络权值,使其达到最优,学习规则可由 BP 学习算法导出为

$$\Delta W = -\eta \frac{\partial J}{\partial W} = -\eta \frac{\partial J}{\partial y_p} \frac{\partial y_p}{\partial u_p} \frac{\partial u_p}{\partial W} = \eta e(k) \frac{\partial y_p}{\partial u_p} \frac{\partial u_p}{\partial W} \quad (5.6)$$

其中  $\eta$  为学习因子; $\partial y_p / \partial u_p$  为未知非线性系统(5.1)的 Jacobi 矩阵。该矩阵的求解可以通过另一个神经网络正向模型进行,也可以采用如下的近似计算<sup>[44]</sup>

$$\frac{\partial y_p}{\partial u_p} = \frac{\Delta y_p}{\Delta u_p} = \frac{y_p(k) - y_p(k-1)}{u_p(k) - u_p(k-1)} \quad (5.7)$$

或

$$\frac{\partial y_p}{\partial u_p} = \frac{\Delta y_p}{\Delta u_p} = \frac{y_p(u + \Delta k) - y_p(u)}{\Delta u_p} \quad (5.8)$$

或

$$\frac{\partial y_p}{\partial u_p} = \left| \frac{\Delta y_p}{\Delta u_p} \right| \cdot \operatorname{sgn} \left( \frac{\partial y_p}{\partial u_p} \right) \quad (5.9)$$

其中(5.9)式是较为常用的一种方法。当  $\Delta y_p / \Delta u_p$  有界时,可将其影响归结到学习因子  $\eta$  中去,从而只取  $\operatorname{sgn}(\partial y_p / \partial u_p)$ ,本章采用这种方法。值得指出的是,人们通常认为,对于单调函数,  $\operatorname{sgn}(\partial y_p / \partial u_p)$  的符号一定,为“+1”或“-1”,从而在系统控制中只取“正号”或“负号”。然而,对于一个静态平面函数而言,要么单调增,要么单调减,  $\operatorname{sgn}(\partial y_p / \partial u_p)$  的符号一定;而对于一个动态球面函数,  $\operatorname{sgn}(\partial y_p / \partial u_p)$  符号是未定的。如对电液伺服系统,就静态系统而言,  $\operatorname{sgn}(\partial y_p / \partial u_p)$  值一定;而对动态系统,  $\operatorname{sgn}(\partial y_p / \partial u_p)$  的值与输入有关,因此必须考虑系统相位的影响,而不能取单一符号,这时定义全局单调性是不恰当的。因此,在使用(5.9)式时,通常采用如下形式

$$\begin{aligned} \frac{\partial y_p}{\partial u_p} &= \operatorname{sgn} \left( \frac{\partial y_p}{\partial u_p} \right) = \operatorname{sgn} \left( \frac{\Delta y_p}{\Delta u_p} \right) \\ &= \operatorname{sgn}(\Delta y_p \Delta u_p) = \operatorname{sgn}(\Delta y_p) \operatorname{sgn}(\Delta u_p) \end{aligned} \quad (5.10)$$

为加快神经网络的动态调节能力,而又不影响收敛时的稳态控制精度,我们提出一种用于直接控制的新的神经网络结构<sup>[159]</sup>,该网络权值由比例、积分、微分三个部分组成,可记为

$$W = W^p + W^I + W^D \quad (5.11)$$

其中:  $W^p$ 、 $W^I$ 、 $W^D$  分别代表权值的比例、积分、微分部分。积分部分具备记忆能力,保证控制系统的连续性;比例和微分部分用于动态调节,当控制收敛时不再起作用。对各部分的调整,可按指标函数的负梯度方向进行,学习规则为

$$W^p = -k_p \partial J / \partial W \quad (5.12)$$

$$\Delta W^I = -k_I \partial J / \partial W \quad (5.13)$$

$$W^D = -k_D \Delta(\partial J / \partial W) \quad (5.14)$$

其中:  $k_p$ 、 $K_I$ 、 $K_D$  为相应的学习因子。可以看出,积分项的学习规则(5.13)式与(5.6)式

一致,实现系统的记忆功能; $W^p, W^D$  仅具备单次调整能力,本次调整不影响下一次的权值调节。

通常,为简化运算,我们仅对网络输出层做上述构造,隐层单元仍采用传统的构造方法,相应的权值调整规则仍采用标准 BP 算法。

对线性系统、弱非线性系统或慢时变系统,可采用 Adaline 网络进行控制,网络输入向量为  $X = [u_m, y_m, y_p]^T$ 。这时,(5.12)~(5.14)式的调整规则可采用改进的 Widrow-Hoff 学习准则<sup>[175]</sup>

$$W^p(k) = R^p v(k) X(k) \operatorname{sgn}(\partial y_p / \partial u_p) \quad (5.15)$$

$$\Delta W^I(k) = R^I v(k) X(k) \operatorname{sgn}(\partial y_p / \partial u_p) \quad (5.16)$$

$$W^D(k) = R^D \operatorname{sgn}(v(k)) |v(k) - v(k-1)| X(k) \operatorname{sgn}(\partial y_p / \partial u_p) \quad (5.17)$$

其中: $R^I, R^p, R^D$  为正定对角阵; $v(k)$  为计算误差,其修正公式为

$$v(k) = \frac{e(k)}{\epsilon + bX(k)RX^T(k)} \quad (5.18)$$

其中: $R = R^I + R^p + R^D, \epsilon > 0, b > 0$  为修正系数。权值调整完毕后,可直接求出系统的控制量为

$$u_p(k) = (W^p(k) + W^I(k) + W^D(k))^T X(k) \quad (5.19)$$

在上述控制律中,如令  $\operatorname{sgn}(\partial y_p / \partial u_p) = 1, R^D = 0$ ,则由上述规则构成的控制率与由 Popov 超稳定性定理得出的自适应控制律相同<sup>[110]</sup>。对于朗道提出的模型参考自适应控制律,可以证明,引入(5.19)式的微分项后( $\operatorname{sgn}(\partial y_p / \partial u_p) = 1$ ),仍能保证系统的超稳定特性<sup>[159]</sup>。可以看出,采用 Adaline 网络进行自适应律的设计时,仅比传统自适应控制率的设计多出一个符号项  $\operatorname{sgn}(\partial y_p / \partial u_p)$ 。

我们知道,传统自适应控制在设计自适应律时,为满足前向通道严格正实这一超稳定性的必要条件,需要在误差反馈通道构造串联滤波器。为简单起见,常常取常值正 1 或负 1。由此产生的结果是系统对低频缓时变信号(相对于系统频带)的控制效果较好,而对高频信号则会产生较大的控制偏差。在相同条件下,Adaline 神经网络控制要比传统自适应控制具有更大的输入空间,因而有可能适应非线性较强的系统控制。

以上讨论了采用 Adaline 网络对线性系统、弱非线性系统或慢时变系统的控制方法。对于一般的非线性系统,可以构造多层神经网络或高阶网络控制器,如 BP 网络、RBF 网络等。本节取 BP 网络结构,隐层单元激化函数设为 Sigmoid 函数;若记隐层输出为  $X_H$ ,则

$$X_H = \sigma(W_{IH}^T X) \quad (5.20)$$

其中: $W_{IH}$  为输入层至隐层的权值矩阵; $X$  为输入向量。网络输出即控制率为

$$u_p = W_{OH}^T X_H \quad (5.21)$$

类似的,网络隐层权值的调整可按传统 BP 算法进行,而输出层权值的学习可借鉴(5.15)~(5.18)式的学习算法。令

$$W_{OH} = W_{OH}^p + W_{OH}^I + W_{OH}^D \quad (5.22)$$

则输出层权值的学习规则为

$$v(k) = \frac{e(k)}{\epsilon + bX_H X_H^T} \quad (5.23)$$

$$W_{OH}^P = R^P \nu(k) X_H \text{sgn}(\partial y_p / \partial u_p) \quad (5.24)$$

$$\Delta W_{OH}^I = R^I \nu(k) X_H \text{sgn}(\partial y_p / \partial u_p) \quad (5.25)$$

$$W_{OH}^D = R^D \text{sgn}(\nu(k)) [\nu(k) - \nu(k-1)] X_H \text{sgn}(\partial y_p / \partial u_p) \quad (5.26)$$

对上述控制算法的收敛性,有如下定理。

**定理 5.1** 对非线性系统(5.1)式,若采用(5.21)~(5.26)式表示的神经网络直接自适应控制算法,能够保证系统输出稳定收敛。

证明:先给出以下假设:

**假设 5.1** 非线性系统(5.1)是连续且满足局部 Lipschitz 条件的 BIBO 系统。

**假设 5.2** 非线性系统(5.1)对给定参考模型(5.2)是控制可达的。

显然,当  $R^P = R^D = 0$  时,神经网络结构中仅含有积分项,即为标准的神经网络直接自适应结构,(5.21)~(5.26)式即退化为标准的 BP 算法,其稳定收敛研究已有现成的结论<sup>[47]</sup>。

当  $R^P, R^D \neq 0$  时,控制率(5.21)式可写为

$$\begin{aligned} u_p &= (W_{OH}^P + W_{OH}^I + W_{OH}^D)^T X_H \\ &= (W_{OH}^I)^T X_H + (W_{OH}^P)^T X_H + (W_{OH}^D)^T X_H \\ &= u_{p1} + u_{p2} + u_{p3} \\ &= u_{p1} + [R^P \nu(k) + R^D \text{sgn}(\nu(k)) [\nu(k) - \nu(k-1)]] X_H^T X_H \text{sgn}(\partial y_p / \partial u_p) \end{aligned} \quad (5.27)$$

当  $\epsilon = 0$  时,将(5.23)式代入上式,得

$$u_p = u_{p1} + (k_1 e(k) + k_2 \dot{e}(k)) \text{sgn}(\partial y_p / \partial u_p) \quad (5.28)$$

其中  $k_1 = R^P / bR, k_2 = R^D \text{sgn}(\nu(k)) / bR$ 。

对多数物理系统,当只考虑静态特性时,有  $\text{sgn}(\partial y_p / \partial u_p) = 1$ ;当  $\text{sgn}(\partial y_p / \partial u_p) = -1$  时,可将负号提前处理,则(5.28)式可简化为:

$$u_p = u_{p1} + k_1(t) e(k) + k_2(t) \dot{e}(k) \quad (5.29)$$

显然,  $k_1 e(k) + k_2 \dot{e}(k) = 0$  可视为一种控制误差轨迹,(5.29)式表示的控制律相当于引入了变增益的比例、微分控制项。 $X_H$  是网络隐层输出,当神经元激活函数为双极性 Sigmoid 函数时,  $X_H$  的取值范围为  $(-1, 1)$ , 是有界函数。因此,当  $R^P, R^D$  取较小值时,系统的稳定性不会因附加了比例、微分控制项而受到影响。

证毕。

由上述分析可见,由于神经网络控制率引入了变增益的比例、微分因子,则根据 PID 控制原理,如果各因子选择得当,则能提高系统的动态调节能力。

## 5.2.2 仿真研究

为验证本节提出的控制策略的有效性,下面分别对离散线性不稳定系统和离散稳定有界非线性系统进行仿真研究。

### 1. 线性不稳定系统的仿真

考查三阶线性离散不稳定系统

$$y_p(k+1) = 0.55y_p(k) + 0.46y_p(k-1) + 0.07y_p(k-2) + 0.1u_p(k) + 0.02u_p(k-1) + 0.03u_p(k-2) \quad (5.30)$$

系统的零点为

$$(-0.1 + 0.5385i), (-0.1 - 0.5385i);$$

极点为


$$1.051, (-0.2505 + 0.062i), (-0.2505 - 0.062i)。$$

可见,该系统存在单位圆外的极点,是一不稳定系统。


为简单起见,取参考模型为

$$y_m(k+1) = 0.6y_m(k) + 0.4u_m(k) \quad (5.31)$$

控制信号分别为阶跃信号和正弦信号,神经网络简单地取为 Adaline 网络,输入层有 3 个神经元,学习参数为  $\epsilon=1, b=0, R^I, R^P, R^D$  为元素为 0.5 的对角阵。为了比较广义 PID 神经网络直接自适应控制算法与传统梯度算法的控制效果,设标准 BP 算法的学习因子为 0.5。采样时间设为 10 毫秒。



(a) 无干扰




(b) 有干扰


图 5-4 基于 BP 算法的阶跃控制

图 5-4 是神经网络直接自适应控制器采用标准 BP 算法的控制结果,图 5-5 是广义 PID 神经网络直接自适应控制算法的控制结果,其中图 5-4(a)和图 5-5(a)的网络初始

权值在 $(-0.25, 0.25)$ 之间随机选取;图 5-4(b)和图 5-5(b)是上述随机赋值的神经网络对系统实施控制 2 次后,也就是神经网络经过 2 次学习后,再以获得的权值作为初始权值对系统进行控制,并在控制开始 1 秒后加 0.5 的阶跃干扰时的跟踪情况。



(a) 无干扰



(b) 有干扰

图 5-5 广义 PID 神经网络直接自适应控制结果

由仿真结果可见,线性神经网络直接自适应控制对线性不稳定系统具有较好的控制效果。与 BP 控制算法相比,本节提出的广义 PID 神经网络直接自适应算法具有更快的收敛速度,收敛时间从 1.6 秒提高到 0.8 秒;抗干扰能力更强,具有良好的鲁棒性。

## 2. 有界非线性系统的仿真

考虑非线性系统

$$y_p(k+1) = \frac{y_p(k)y_p(k-1)[y_p(k)+1.5]}{1+y_p^2(k)+y_p^2(k-1)} + u_p(k) \quad (5.32)$$

不加控制时,该系统对单一频率正弦波的响应,如图 5-6 所示。可见波形关于纵坐标轴不对称,表明系统具有较强的非线性特征。

为检验广义 PID 神经网络直接自适应控制器对非线性系统的控制效果,设系统的参考模型为

$$y_m(k+1) = 0.7y_m(k) + 0.3u_m(k) \quad (5.33)$$




图 5-6 系统的开环响应

参考控制输入为

$$u_m(kT) = \sin(2\pi kT) + \sin(4\pi kT) \quad (5.34)$$

其中  $k$  为采样时刻;  $T$  为采样时间, 取为 10 毫秒。

本节采用两类神经网络结构来设计直接自适应控制器, 其中广义 PIDBP 网络结构设为  $5 \times 6 \times 1$ , 广义 PID\_Adaline 网络结构取为  $5 \times 1$ , 网络初始权值在  $(-0.25, 0.25)$  之间随机选取, 学习参数为  $\epsilon = 1, b = 0, R^I, R^P, R^D$ , 为元素 0.5 的对角阵。网络输入向量为  $(u_m, y_m, y_p, u_p, e)$ , 其中  $e$  是控制误差。

为保证控制效果, 先将上述随机赋值的神经网络控制器投入运行, 经过一段时间的控制和学习后, 将获得的权值作为神经网络控制器的初始权值, 再次投入运行, 对系统进行控制。

图 5-7 和图 5-8 分别给出了两种网络对谐波响应的控制结果。由图可见, PIDBP 两网的控制效果比较理想, 且对 0.7 秒时刻幅度为 0.5 的阶跃干扰有较强的抑制能力。广义 PID\_Adaline 网络的控制效果略逊于 BP 网络, 这与 Adaline 网络对非线性函数的逼近能力较差是一致的。但要指出的是, 采用一般的 MRAC 控制时, 效果很差; 且对阶跃干扰易发散<sup>[159]</sup>。




图 5-7 广义 PIDBP 神经网络直接自适应控制结果






图 5-8 广义 PID-Adaline 神经网络直接自适应控制结果

## 5.3 模型参考混合神经网络直接自适应控制器设计

### 5.3.1 控制器结构及控制算法

由前面的分析可知,与一般自适应控制相比,线性 Adaline 网络在参数调整方面具有更大的灵活性;而与 BP 网络相比,学习又不够精细。BP 网络在局部区域有较快的搜索能力,但全局收敛较慢,这是由于 BP 网络采用的学习算法本质上是一种梯度算法。当权值调整梯度  $\partial J / \partial W = 0$  时,学习达到某一极值而陷于局部最小。如果能够保证梯度  $\partial J / \partial W = 0$  的解惟一,或者在学习过程中  $\partial J / \partial W \neq 0$ ,则可保证收敛结果为全局最优。文献 [188] 从函数辨识的角度构造混合神经网络,网络输入是被辨识函数输入的高次项,从而使得梯度矩阵  $\partial J / \partial W$  满秩,因而从理论上保证了所构造的混合网络的全局优化能力。但是这种方法对自适应线性单元输入层的要求甚严,且须知道系统阶数。当系统阶数较高时,线性单元的输入是高次项,易混入杂波噪声,在工程控制中欠实用。

从自适应控制的角度来看,大多数实时控制任务都是在某些工作点附近进行的,而且控制任务比较单一,对控制的要求无需数学理论要求的那么“完备”,全局收敛和局部收敛的矛盾不十分明显,只要保证控制误差在要求的范围内即可。我们知道,高精度和快速性是伺服系统追求的目标,这就要求控制器具备快速的工作点切换能力以及在工作点上的误差跟随和抗扰能力。为此,我们构造一种混合神经网络自适应控制结构,如图 5-9 所示。其中的非线性网络可以是 BP 网络、动态递归网络、CMAC 网络、B 样条网络、径向基函数网络等,本节选择 BP 网络。线性网络可以根据对系统的了解程度进行选择,可以是线性定常控制律,也可以是 Adaline 神经网络。

为叙述方便,重写(5.1)式和(5.2)式如下

$$y_p(k+1) = f[y_p(k), \dots, y_p(k-n), u_p(k), \dots, u_p(k-m)] \quad (5.35)$$

$$y_m(k+1) = A_m y_m(k) + B_m u_m(k) \quad (5.36)$$

为实现上述系统对参考模型的跟踪,对图 5-9 所示的控制结构,控制率为

$$u_p(k) = u_{p1}(k) + u_{p2}(k) \quad (5.37)$$

其中  $u_{p1}$ 、 $u_{p2}$  分别为线性网络和非线性网络的输出

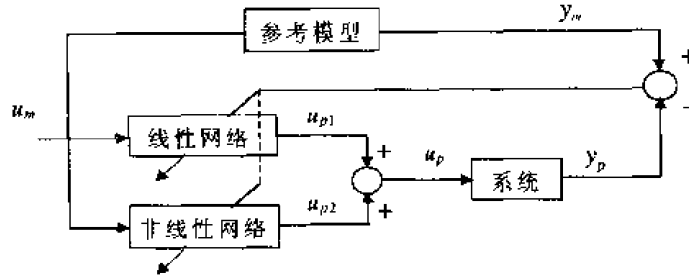


图 5-9 模型参考混合神经网络直接自适应控制结构

$$u_{p1} = W^T X(k) \quad (5.38)$$

$$u_{p2} = W_{OH}^T \sigma(W_{HI}^T X(k)) \quad (5.39)$$

其中:  $W$  为 Adaline 线性网络的权值向量;  $W_{OH}$  为非线性网络隐层至输出层的权值向量;  $W_{HI}$  为输入层至隐层的权值矩阵;  $\sigma(x)$  为神经元激活函数, 取为对称 Sigmoid 函数; 网络输入向量为  $X(k) = [y_d(k), y_m(k), y_p(k), e(k)]^T$ 。线性神经元与非线性网络可以有相同的输入向量, 也可以取不同的向量。

以往, 在神经网络控制中, 我们将系统完全作为“黑箱”对待, 网络初始权值的选择是盲目的。在随机选取初值的情况下, 系统会产生什么样的控制行为不得而知; 若初始权取零值, 则可能产生振荡甚至会影响到系统的稳定性。在本节构造的控制策略(5.37)式中, 由于 Adaline 线性网络初值的选择可以根据对系统信息的了解来设计, 稳定性也可以由古典控制理论或 Lyapunov 方法等给出定性的证明, 因此, 可将多层非线性网络的输出层权值设为零或非常小的数, 从而避免了盲目取值的影响。如果能估计系统非线性程度的大小, 还可以将多层非线性网络的输出函数设计成有相应变化范围的非线性函数。

为提高图 5-9 所示结构的适应性, 引入一个平衡机制, 将系统的实际控制输入修正为线性网络和非线性网络输出的加权和

$$u_p(k) = \alpha u_{p1}(k) + \beta u_{p2}(k) \quad (5.40)$$

其中:  $\alpha, \beta$  为加权系数。这样, 根据对系统先验知识的了解, 或依据系统非线性程度的强弱, 选择控制器的权重, 就可以实现不同的控制需要。

定义系统的性能指标为

$$J = \frac{1}{2} [y_m(k) - y_p(k)]^2 \quad (5.41)$$

则网络权值的调节就可以采用 BP 算法进行了。对线性网络, 学习规则为

$$\Delta W = -\eta_1 \frac{\partial J}{\partial W} = \eta_1 e X \operatorname{sgn}\left(\frac{\partial y_p}{\partial u_p}\right) \quad (5.42)$$

同样, 对非线性网络, 学习规则为

$$\Delta W_{OH} = -\eta_2 \frac{\partial J}{\partial W_{OH}} = \eta_2 e X_H \operatorname{sgn}\left(\frac{\partial y_p}{\partial u_p}\right) \quad (5.43)$$

$$\Delta W_{HI} = -\eta_2 \frac{\partial J}{\partial W_{HI}} = \eta_2 e W_{OH}^T \sigma'(W_{HI}^T X) X^T \operatorname{sgn}\left(\frac{\partial y_p}{\partial u_p}\right) \quad (5.44)$$

以上两种网络权值的学习是分开进行的, 因此也可以选择不同的学习方式, 二者互

不影响,但计算结果具有很强的关联性。我们注意到,应用混和神经网络进行控制时,显然增加了算法的执行时间。但随着计算机硬件技术的不断发展和价格的逐年下降,这一点已不成问题。如同一执行程序在 486/66 上运行约需 10ms,而在“Pentium100”上运行则不足 2ms,这一执行速度对大多数实时控制任务已足够了。

综合以上分析,混合神经网络直接自适应控制算法的实现步骤如下:

- ① 设置网络结构与学习参数:  $\alpha$ 、 $\beta$ 、 $\eta_1$ 、 $\eta_2$ 。
- ② 在时刻  $k$ , 采样  $y_m(k)$ 、 $y_p(k)$ , 求跟踪误差  $e(k) = y_m(k) - y_p(k)$ 。
- ③ 根据(5.42)~(5.44)式分别调整  $W$ 、 $W_{OH}$ 、 $W_{HI}$ 。
- ④ 根据(5.38)~(5.39)式计算  $u_{p1}(k)$  和  $u_{p2}(k)$ 。
- ⑤ 由(5.40)式计算控制器输出。
- ⑥  $k = k + 1$ , 对各参数进行移位处理, 返回步骤②。

下面来分析控制算法的收敛性。

假定决定控制量的神经网络权值按(5.42)~(5.44)式调整后, 系统误差向减小方向变化, 则认为该控制算法收敛。设  $y_d$  是参考模型输出或期望输出, 则系统的输出跟踪误差为

$$\begin{aligned} e(k+1) &= y_d - y_p(k+1) \\ &= y_d - (y_p(k) + \Delta u \partial y_p / \partial u_p) \\ &= e(k) - \Delta u \partial y_p / \partial u_p \end{aligned} \quad (5.45)$$

由(5.37)式得

$$\Delta u = \Delta u_{p1} + \Delta u_{p2} \quad (5.46)$$

其中

$$\Delta u_{p1} = \Delta W X = \eta_1 e(k) \operatorname{sgn}(\partial y_p / \partial u_p) X^T X \quad (5.47)$$

$$\begin{aligned} \Delta u_{p2} &= (W_{OH} + \Delta W_{OH})^T (X_H + \Delta X_H) - W_{OH}^T X_H \\ &= \Delta W_{OH}^T \Delta X_H + \Delta W_{OH}^T X_H + W_{OH}^T \Delta X_H \end{aligned} \quad (5.48)$$

又因为

$$\begin{aligned} \Delta X_H &= \sigma(W_{HI}^T X + \Delta W_{HI}^T X) - \sigma(W_{HI}^T X) \\ &= \Delta W_{HI}^T X \dot{\sigma}(W_{HI}^T X) \end{aligned} \quad (5.49)$$

将上式代入(5.48)式, 得

$$\begin{aligned} \Delta u_{p2} &= \Delta W_{OH}^T \Delta X_H + \Delta W_{OH}^T X_H + W_{OH}^T \Delta X_H \\ &= \Delta W_{OH}^T \sigma(W_{HI}^T X + \Delta W_{HI}^T X) + W_{OH}^T \dot{\sigma}(W_{HI}^T X) (\Delta W_{HI}^T X) \\ &= \Delta W_{OH}^T [X_H + \Delta W_{HI}^T X \dot{\sigma}(W_{HI}^T X)] + W_{OH}^T \dot{\sigma}(W_{HI}^T X) (\Delta W_{HI}^T X) \\ &= \eta_2 e(k) \operatorname{sgn}(\partial y_p / \partial u_p) \cdot \{ X_H^T X_H \\ &\quad + \eta_2 e(k) \operatorname{sgn}(\partial y_p / \partial u_p) X_H^T \dot{\sigma}^T(W_{HI}^T X) W_{OH} X \dot{\sigma}(W_{HI}^T X) \\ &\quad + \eta_2 e(k) \operatorname{sgn}(\partial y_p / \partial u_p) W_{OH}^T \dot{\sigma}(W_{HI}^T X) \dot{\sigma}^T(W_{HI}^T X) W_{OH} X \} \\ &= \eta_2 e(k) \operatorname{sgn}(\partial y_p / \partial u_p) g(X, X_H) \end{aligned} \quad (5.50)$$

其中

$$g(X, X_H) = X_H^T X_H + \eta_2 e(k) \operatorname{sgn}(\partial y_p / \partial u_p) X_H^T \hat{\sigma}^T(W_{HI}^T X) W_{OH} X \hat{\sigma}(W_{HI}^T X) \\ + \eta_2 e(k) \operatorname{sgn}(\partial y_p / \partial u_p) W_{OH}^T \hat{\sigma}(W_{HI}^T X) \hat{\sigma}^T(W_{HI}^T X) W_{OH} X$$

将(5.50)和(5.47)式代入(5.46)式,再代入(5.45)式,得

$$e(k+1) = e(k)[1 - (\eta_1 X^T X + \eta_2 g(X, X_H) \operatorname{sgn}(\partial y_p / \partial u_p))] \\ = e(k)(1 - R(X)) \quad (5.51)$$

可见,如果 $|1 - R(X)| < 1$ ,则上式收敛。显然,当 $\eta_2 = 0, \eta_1 \neq 0$ ,且 $X^T X$ 有界时,可以保证收敛;同样,当 $\eta_2 \neq 0, \eta_1 = 0$ 时,也可以保证收敛。

由上述证明可知,当仅对 $W_{OH}$ 调节, $W_{HI}$ 不调节,而选择单层非线性网络如B样条、CMAC、BRF时,同样能够保证相应的收敛条件,但收敛速度有所差异。从实用角度出发,选择局部收敛的非线性网络可能比BP网络更加有效。

上述证明虽然说明了保证控制收敛的参数 $\eta_1, \eta_2$ 是存在的,如取足够小,但不能给出任何指导性的取值建议。通常,我们可以先设定 $\eta_2 = 0$ 时,得到系统收敛的 $\eta_{\max}$ 值,然后取 $\eta_1 = 0.8\eta_{\max}, \eta_2 = -0.2\eta_{\max}$ 作为参考取值。当然,这里还不能给出确切的数值,它与具体系统的参数及采样时间等有关<sup>[159]</sup>。

### 5.3.2 仿真研究

考虑摄动非线性系统

$$y_p(k+1) = \frac{y_p(k) + 0.2y_p(k-1)}{1 + \alpha y_p^2(k)} + [\beta + u_p(k)]u_p(k)u_p(k-1) \quad (5.52)$$

其中 $\alpha \in (0.9, 1.1), \beta \in (0.3, 0.7)$ 是摄动参数。图5-10给出该系统不加控制时,对1Hz正弦信号的输出响应曲线,图5-11是在0.7秒时存在幅值为0.5的阶跃干扰时的开环响应曲线。可以看出,该系统的非线性特征比较明显,当输入有变化时,输出波形变化很大。

我们采用模型参考混合神经网络控制器对系统实施控制,设参考模型为




图5-10 无干扰时系统的开环响应




图 5-11 有阶跃干扰时系统的开环响应

$$y_m(k+1) = 0.7y_m(k) + 0.3u_m(k) \quad (5.53)$$

神经网络控制器由两部分组成,其中线性网络取  $4 \times 1$  的广义 PID 网络,输入向量为  $[y_d, y_m, y_p, e]^T$ ,相应的初始权值为  $[1, 0, 0, 0.5]$ ,学习率为  $\eta_1 = 0.35$ 。BP 网络结构为  $6 \times 6 \times 1$ ,输入向量为  $\{u_m(k), y_m(k), y_p(k), e(k), u_p(k-1), y_p(k-1)\}$ ,网络初始权值取  $(-0.1, 0.1)$  间的随机数,隐层单元采用对称 Sigmoid 激化函数,输出单元取线性函数,学习率为  $\eta_2 = 0.30$ 。采样时间为 10 毫秒,参考输入为正弦信号。

图 5-12 给出了存在阶跃干扰时混合神经网络的控制结果,可见控制效果非常明显。曲线上的高频纹波是由于系统参数变化引起网络权值较大幅度的频繁调整产生的,可以进一步通过学习参数的调整、控制输出滤波、权值惯量修正等措施加以改善。




图 5-12 混合神经网络实时闭环控制结果

## 5.4 本章小结

本章提出了两类神经网络模型参考直接自适应结构。从经典 PID 控制思想出发,提出了具有 PID 权值形式的网络结构,并基于该网络,设计了神经网络直接自适应控制策

略和相应的学习算法。结合线性网络和多层前馈网络的特点,提出了具有大范围快速学习和局部精细搜索能力的混合神经网络直接自适应控制策略,可有效避免神经网络陷入局部最小,同时使神经网络直接控制器具有灵活的输入形式和不变的控制器结构。理论分析和数字仿真研究均表明,本章提出的两种控制策略泛化能力强、收敛较快,设计的控制器结构简单,鲁棒性强,可满足实时控制的需要,并具有较为广泛的实用意义。

文中控制器的设计与分析虽然是针对 SISO 系统进行的,但其方法和结论可推广到 MIMO 系统中。

神经网络直接自适应控制器因结构简单、控制目标明确、动态调节能力强,在工程控制中具有一定的应用潜力。但由于网络结构及初值选取缺乏有效的理论指导,在实际应用中会产生这样或那样的问题。如控制器的参数是根据直接输出误差调整的,每个采用时刻控制参数的跟踪调节迅速,而在实际系统中,由于受驱动控制电流和惯性等物理因素的限制,不可能将被控对象一步调整到位。这样以系统输出误差为调节目标的神经网络直接自适应控制器 NNDAC,在动态调节过程中,容易造成控制参数的过度调整或饱和,而影响系统的控制品质。这一情况在系统变化较大或干扰严重时尤为突出。文献[73]将模糊思想引入 NNDAC 中,进行误差信息的滤波,有可能解决这一问题。构成的控制结构如图 5-13 所示。




图 5-13 模糊神经网络直接控制结构

事实上,模糊控制作为一种智能控制手段,具有处理模糊语言信息的能力,可模拟人类智慧进行判断和决策,而这一点正是目前人工神经网络所缺乏的。模糊控制与其说是一种控制策略、控制算法,毋宁说是一种控制思想更为恰当。由于它更接近于人脑的思维方式,因而在控制系统的设计上具有较大的自由度,尤其在噪声和干扰的抑制方面具有明显的优势。如在图 5-13 所示控制结构中,系统的输出误差通过模糊滤波,分解成若干过程调节目标,再参与 NNDAC 网络权值的调整,则有可能改善神经网络控制器的动态调节能力,有效防止控制量的过度调节及饱和。

## 第六章 神经网络在线自学习模糊自适应控制

### 6.1 引言

在第四章的 NNPSLRATC 方案中,采用了双 NN 结构。控制器在工作过程中,需要在线辨识被控对象的神经模型 NNM,导致系统的设置参数和调节参数过多,运算量大;而且,由于没有采用系统的直接输出误差来训练控制器,控制性能的优劣在很大程度上取决于 NNM 的辨识精度。另外,为保证控制的实时性,NNPSLRATC 采用了双处理器并行结构,使控制系统设计变得复杂,在实际工程控制中实用性欠佳。这一方案属间接自适应控制<sup>[44]</sup>。

第五章讨论了另一类神经网络自适应控制方法:直接自适应控制<sup>[57]</sup>。它是直接依据过程的输出信息来调整控制参数的,不需要预先知道系统的动力学特性或在线辨识系统的模型。这一点也正是传统的自适应控制所不能解决的<sup>[193]</sup>。这种控制器是直接依据控制精度设计的,不需经过事先训练,也不依赖于对象的辨识模型,具有较好的动态响应性能和稳态精度<sup>[194,195]</sup>。但由于被控对象的未知特性,BP 类学习算法无法直接应用。

Kawato 等人在直接自适应系统中,通过并联一个普通的反馈控制器,对系统实行初始稳定控制,并利用反馈误差学习法<sup>[199]</sup>来训练神经网络,使之成为系统的逆动力学模型,构成一种监督控制结构<sup>[200]</sup>,从而解决了上述问题。实验证明,基于反馈误差学习法的神经网络控制器 NNC 对机器人轨迹跟踪<sup>[201]</sup>、空间机械手<sup>[202]</sup>、倒立摆系统<sup>[197]</sup>、汽车刹车系统<sup>[203]</sup>和电液伺服系统<sup>[204]</sup>等均具有良好的控制品质。在这种控制结构中,传统的反馈控制器保证对系统的全局渐近稳定控制,同时用作被控对象的逆参考模型。其主要优点是控制和学习同时进行,不需要特定的教师信号,且设计简单,实现方便,特别适用于时变不确定系统的神经网络在线学习控制。

在反馈误差学习控制方案中,控制品质依赖于 NNC 逼近系统逆动力学模型的精度。而网络学习的优劣在很大程度上与反馈控制器的参数有关。由于工业系统的惯性,系统的控制通常存在过渡过程,一般不会从某个初始状态跃变到期望的目标状态。反馈误差学习法直接利用反馈控制器的输出信号来训练 NNC,这就可能造成 NNC 的输出与系统的实际跟踪过程不相匹配,而导致 NNC 的学习产生振荡或进入饱和状态,进而影响系统的控制品质。这一情况在系统受到干扰或运行条件发生变化时更易发生。

考虑一般系统的未知、不确定、时变和非线性特性,本章在传统反馈误差学习法的基础上,提出一种神经网络在线自学习模糊自适应控制结构。利用模糊推理机产生的分目标学习误差<sup>[73]</sup>代替反馈控制器的输出信号训练 NNC,使 NNC 的学习与系统的实际跟踪过程相适应,避免了控制器的输出产生振荡或进入饱和状态。实践表明,这种方法将模糊逻辑推理结合进神经网络控制中,可有效提高系统的控制品质,实现对未知不确定非线性系统的高精度平稳控制。为比较不同方法控制性能的优劣,本章还给出了基于传统反馈误差学习法的控制实验结果。

## 6.2 神经网络在线自学习模糊自适应控制器设计

### 6.2.1 控制器结构及工作原理

综合反馈误差学习法和直接自适应控制的特点,提出的神经网络在线自学习模糊自适应控制结构如图 6-1 所示,它由一个普通的反馈控制器(FC)和一个神经网络控制器(NNC)组成,二者的输出信号之和作为实际控制量对系统进行控制

$$u(k) = u_n(k) + u_f(k) \quad (6.1)$$

其中: $u_f$  是反馈控制器的输出; $u_n$  是神经网络控制器的输出,通常可描述为

$$u_n(k) = NN[r(k), e(k), w(k), \theta(k), \sigma(x)] \quad (6.2)$$

其中: $r$  是参考输入; $e$  为系统跟踪误差; $w(k)$ 、 $\theta(k)$  分别是神经网络的连接权和神经元的输入偏置; $\sigma(\cdot)$  为神经元激活函数,取其形式为对称 Sigmoid 函数。

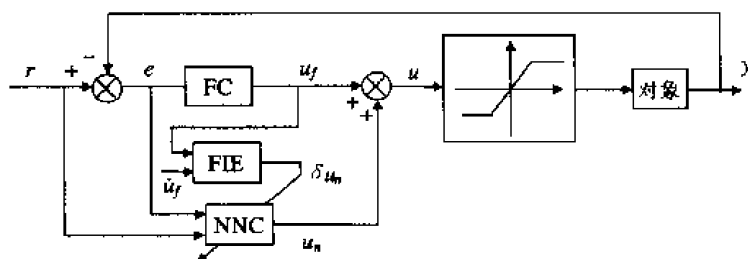


图 6-1 神经网络在线自学习模糊自适应控制结构

反馈控制器 FC 起着监督控制的作用,在 NNC 训练初期,FC 对系统实施启动控制,并保证闭环系统的稳定性;神经网络控制器 NNC 是一个在线学习的自适应控制器,其作用是综合系统的参考输入和跟踪误差,利用模糊推理机 FIE 的输出信号进行学习,不断逼近被控对象的逆动力学,使 FC 的输出及其变化趋于零,从而逐步取消 FC 的作用,实现对系统的高精度跟踪控制。这两个过程是同时进行的。

可以看出,在控制初期,神经网络控制器 NNC 未经训练,反馈控制器起主要作用,NNC 通过 FIE 的输出信号不断得到训练,并逐渐在控制行为中占据主导地位,最终取代反馈控制器,而单独对系统实施高精度控制;当系统受到干扰或对象发生变化时,反馈控制器重新起作用,通过补偿控制,消除上述因素对控制系统的影响,同时为 NNC 提供训练误差。这种控制策略学习与控制同时进行,且完备性好,具有良好的鲁棒性以及适应对象和环境变化的能力。

### 6.2.2 神经网络控制器(NNC)及其训练

由于一个三层神经网络就具有任意逼近能力<sup>[143~146]</sup>,因此,NNC 采用一个单隐层线性输出前馈网络,其模型结构如图 6-2 所示,输入输出关系可描述为

$$u_n(k) = W_{OH}^T(k) \sigma[W_{HI}^T(k) X_1(k) + \theta_H(k)] \quad (6.3)$$

其中: $X_1 = [r, e(k), \dots, e(k-m+1)]$  是网络的输入向量; $W_{OH}(k)$ 、 $W_{HI}(k)$  分别是 NNC 输出层到隐层和隐层到输入层的权值矩阵; $\theta_H(k)$  是隐层单元的输入偏置。






图 6-2 NNC 模型结构

根据反馈误差学习法,网络权值的学习规则为<sup>[201]</sup>

$$\frac{dw(t)}{dt} = \eta(t) \left( \frac{\partial u_n(t)}{\partial w(t)} \right)^T u_f(t) \quad (6.4)$$

其中:  $\eta$  为学习步长;  $u_f(t)$  为学习误差,即反馈控制器的输出信号。文献[197,202]的研究表明,在学习期间无外部干扰的情况下,基于上述学习规则的神经网络控制方案能大幅度降低系统的跟踪误差,取得很好的控制效果。然而,在实际系统中,干扰和噪声是普遍存在的;另一方面,在 NNC 训练初期,由于系统存在较大的跟踪误差,直接采用 FC 的输出信号训练神经网络时,常常使网络的输出产生振荡或进入饱和状态,造成系统响应很慢或控制初期输出产生抖动<sup>[204,205]</sup>。

事实上,由于工业控制系统存在惯性,通常不能从某个状态跃变到另一个状态。如对某电液伺服系统而言,液压缸的最大运动速度为 0.5 米/秒,要完成最大行程( - 100mm, 100mm)的位移运动,需要 400 ms 的时间,这意味着即使控制量再大,液压缸也需要经过多个控制周期,才能到达目标状态。因此,也就无须要求控制器的输出从某个初始值一次跃变到最终的期望值了。

为改善网络的学习效果,使 NNC 的输出变化与系统的运动特性相匹配,我们根据误差和误差变化,将系统的最终目标分解成若干个分目标。控制系统在每个采样周期中实现对一个分目标的跟踪。经过若干控制周期后,系统即可平滑地到达最终目标状态。在分目标跟踪过程中,神经网络控制器的学习误差不再基于系统的最终目标误差,而是基于该时刻系统所应消除的分目标误差。采用分目标学习方式,不仅使 NNC 在每个采样周期中的学习目标易于实现,使系统的跟踪控制更符合工业过程的实际,而且可有效避免 NNC 的输出产生振荡或进入饱和状态。

分目标学习误差由模糊推理机的一组模糊规则给出,如表 6-1 所示<sup>[136]</sup>。表中符号 PB、PM、PS、0、NS、NM、NB 分别表示正大、正中、正小、零、负小、负中、负大等概念。表中的模糊关系不再是传统意义上的模糊控制策略,而是每一控制周期中用于 NNC 训练的分目标学习误差。这样,NNC 在学习过程中,逐步跟踪系统的逆动力学,并产生一自适应控制信号,使系统输出跟踪给定的参考信号。它消除的不再单纯是系统的输出误差,而是误差和误差变化的综合影响,从而避免了反馈误差学习法可能造成的 NNC 的输出产生振荡或进入饱和状态等问题。

表 6-1 分目标学习误差规则表

$\delta \backslash \dot{U}_f$	$U_f$	NB	NM	NS	0	PS	PM	PB
NB		PB	PB	PB	PM	PM	PS	0
NM		PB	PB	PM	PM	PS	0	NS
NS		PB	PM	PM	PS	0	NS	NM
0		PM	PM	PS	0	NS	NM	NM
PS		PM	PS	0	NS	NM	NM	NB
PM		PS	0	NS	NM	NM	NB	NB
PB		0	NS	NM	NM	NB	NB	NB

为实现上述模糊推理规则,必须对 FIE 的输入变量进行模糊化处理,即将输入变量从基本论域转化到相应的模糊论域。为此,引入 FC 输出变量  $u_f$  及其变化变量  $\dot{u}_f$  的量化因子  $K_{u_f}$ 、 $K_{\dot{u}_f}$ 。假定变量  $u_f$  的基本论域和模糊论域分别为  $(-u_{fm}, u_{fm})$  和  $(-n_{u_f}, -n_{u_f} + 1, \dots, 0, \dots, n_{u_f} - 1, n_{u_f})$ , 且变量  $\dot{u}_f$  的基本论域和模糊论域分别为  $(-\dot{u}_{fm}, \dot{u}_{fm})$  和  $(-n_{\dot{u}_f}, -n_{\dot{u}_f} + 1, \dots, 0, \dots, n_{\dot{u}_f} - 1, n_{\dot{u}_f})$ , 则量化因子  $K_{u_f}$ 、 $K_{\dot{u}_f}$  可由下式确定

$$K_{u_f} = \frac{n_{u_f}}{u_{fm}} \quad (6.5)$$

$$K_{\dot{u}_f} = \frac{n_{\dot{u}_f}}{\dot{u}_{fm}} \quad (6.6)$$

则 FC 的实时输出信号  $u_f$  及其变化  $\dot{u}_f$  经量化后的模糊变量  $U_f(k)$ 、 $\dot{U}_f(k)$  分别为

$$U_f(k) = K_{u_f} u_f(k) \quad (6.7)$$

$$\dot{U}_f(k) = K_{\dot{u}_f} \dot{u}_f(k) \quad (6.8)$$

模糊变量  $U_f(k)$ 、 $\dot{U}_f(k)$  的论域、模糊子集及其隶属函数  $\mu$  的定义如图 6-3 所示。为改善模糊推理机的输出特性, FIE 输出变量  $\delta$  的论域、模糊子集及其隶属函数的定义如图 6-4 所示。当系统偏差较大时, 模糊集隶属函数的分辨率较低, FIE 的输出变化比较缓慢, 可保证 NNC 的学习比较平稳; 而当系统偏差较小时, 模糊集隶属函数的分辨率较高, 有利于提高 NNC 学习的收敛精度。




图 6-3 FIE 输入变量的隶属函数




图 6-4 FIE 输出变量的隶属函数

在控制过程中,系统根据每一采样时刻 FC 的输出信号及其变化,由图 6-3 确定各模糊集的隶属度,然后利用模糊推理规则表 6-1,确定图 6-4 中 FIE 输出变量  $\delta$  所有可能的模糊截集,并以重心法进行模糊判决,得到分目标学习误差  $\Delta E$

$$\Delta E = \frac{\sum_{\delta=-6}^6 \delta \mu(\delta)}{\sum_{\delta=-6}^6 \mu(\delta)} \quad (6.9)$$

为提高模糊判决精度,上式中离散计算步长取为 0.1。与模糊量化过程相反, $\Delta E$  必须还原到其基本论域中,方可用于 NNC 的学习。为此,将  $\Delta E$  乘以一个比例因子  $K_\delta$

$$\delta_r(k) = K_\delta \Delta E(k) \quad (6.10)$$

量化因子和比例因子均是用于论域变换的变量,其大小对控制系统的动态性能影响较大,选配时应兼顾响应速度和超调量。

确定分目标学习误差后,定义 NNC 的训练误差函数如下

$$E = \frac{1}{2} \delta_r^2 \quad (6.11)$$

则利用 2.6 节的 GCAQBP 算法就可以对神经网络控制器 NNC 进行训练了,其权值修正公式可导出为

$$\Delta w'_{OH}(k+1) = -\eta \delta_{u_n}(k) y_H^i(k) + \alpha \Delta w'_{OH}(k) \quad (6.12)$$

$$\Delta w'_{IH}(k+1) = -\eta \delta_H^i(k) x_1^i(k) + \alpha \Delta w'_{IH}(k) \quad (6.13)$$

$$\delta_{u_n}(k) = \delta_r \quad (6.14)$$

$$\delta_H^i(k) = \sigma'(x_{IH}^i(k)) \delta_{u_n}(k) w'_{OH}(k) \quad (6.15)$$

$$\eta = \lambda E^\mu / \|\nabla_w E\|^2 \quad (6.16)$$

$$\|\nabla_w E\|^2 = \sum_{i=1}^{N_H} (\delta_{u_n}(k))^2 (y_H^i(k))^2 + \sum_{i=1}^{N_H} \sum_{j=1}^{m+1} (\delta_H^i(k))^2 (x_1^j(k))^2 \quad (6.17)$$

$$\lambda = \lambda_0 / (1 + E) \quad (6.18)$$

其中: $\alpha$  是动量因子; $0 < \mu < 1$ ;  $N_H$  为控制网络隐层单元数; $\lambda_0$  为 NNC 的初始学习增益。

综上所述,NNOLFAC 的算法实现步骤如下:

① 初始化 FC 及 NNC 的结构、参数及各种训练参数: $\lambda_0$ 、 $\mu$ 、 $\alpha$ 、 $\varepsilon$ 、 $K_{u_n}$ 、 $K_{\dot{u}_j}$ 、 $K_\delta$ 。

- ② 在时刻  $k$ , 采样  $y(k)$ 、 $r(k)$ , 并计算系统输出偏差。
- ③ 计算反馈控制器 FC 的输出信号  $u_f(k)$  及其变化量  $\dot{u}_f(k)$ 。
- ④ 根据模糊推理规则, 按 (6.7)~(6.10) 式求出 NNC 分目标学习误差  $\delta_e(k)$ 。
- ⑤ 若  $\delta_e(k) > \epsilon$ , 按 (6.12)~(6.18) 式修正 NNC 的权值, 否则, 继续下一步。
- ⑥ 构造 NNC 的输入向量  $X_1 = \{r(k+1), e(k), \dots, e(k-m+1)\}$ , 并计算其输出  $u_n(k)$ 。
- ⑦ 计算控制器输出  $u(k)$ , 并送给被控对象, 产生下一步输出  $y(k+1)$ 。
- ⑧ 令  $k = k+1$ , 对  $\{y(k)\}$ ,  $\{u(k)\}$ ,  $\{e(k)\}$  进行移位处理, 返回步骤②。

在控制过程中, NNC 利用模糊推理机输出的分目标学习误差进行学习, 在线调整自己, 逐渐使 FC 的输出趋于零, 从而在控制中占据主导地位, 最终取消 FC 的作用。随着 NNC 权值的调整, 当分目标学习误差收敛到一给定精度时, NNC 的训练暂告结束。此时, 我们认为, NNC 已能很好地代表对象的逆动力学特性, 完全取代 FC, 对系统实行高品质控制。当系统出现干扰或对象发生变化时, 反馈控制器 FC 重新起作用, NNC 也将重新进入学习状态。这种控制策略具有良好的完备性, 不仅可确保控制系统的稳定性和鲁棒性, 而且可有效提高系统的精度和自适应能力。

可见, 与其他控制方法相比, NNOLFAC 方法具有以下特点:

① 控制系统无须辨识被控对象的模型, 可通过反馈误差进行学习, 完成 NNC 的在线设计。系统的控制过程和 NNC 的学习过程同时进行, 不存在学习速度慢的问题; 网络学习不需要特定的教师信号, 避免了离线训练通常存在的训练数据不足的问题。使得控制系统具有更强的适应能力, 可有效处理对象的时变不确定性。

② NNC 是利用模糊推理机产生的分目标学习误差进行训练的, 不仅避免了采用系统直接输出反馈误差进行训练所存在的权值饱和与过调整问题, 实现了对复杂系统的快速无超调控制, 而且可充分滤去控制过程中测量噪声的影响, 有利于提高系统的控制品质。

③ 启动 NNC 前, 在反馈通道引入的控制器 FC 起着监督控制作用, 对系统实施渐近稳定控制, 不仅增强了神经网络控制策略的完备性, 使整个控制系统具有良好的稳定性和鲁棒性, 而且在系统出现干扰时, 可通过 FC 的反馈补偿控制, 有效提高系统的精度和自适应能力。

### 6.3 神经网络控制系统的能控性和稳定性分析

能控性是指对某一系统, 找到一控制输入, 使系统在有限步内, 从某一状态变化到另一状态。

对线性时不变系统, 能控性条件比较容易满足。传统的线性控制方法就能取得满意的效果。但对非线性且参数大范围改变的复杂系统而言, 传统方法乃至本质上非线性的自适应控制方法都难以取得满意的效果, 甚至不能稳定工作。这是因为自适应系统中的辨识模型总是对过程的一种近似, 难免存在未建模的动态。这种动态特性可以使非线性系统的稳定性条件遭到破坏, 而产生不稳定现象。

NNCS 也是一种非线性系统。但是, NNCS 中的非线性与自适应系统的非线性有着

本质的区别。后者的非线性仅是一般智能控制系统表现出来的一种外部特性,而 NNCS 的核心是神经网络控制器 NNC,它是模拟人脑神经思维和决策功能的非线性控制器,具有显著的智能特征<sup>[11,83]</sup>。主要表现在它具有良好的自学习、自适应和处理非线性问题的能力。在控制过程中,尽管表示过程动力学和逆动力学的神经网络模型也是对过程的一种近似,但 NNC 能根据环境和任务的变化,在线获取信息,通过自学习和自适应过程,不断优化控制参数;当调整参数不能满足希望的指标要求时,NNCS 能自动跟踪系统的控制目标,改变控制器结构,调整控制策略,获取整体最优性能。

众所周知,熟练的操作者对复杂系统通常具有良好的控制能力。这是因为人通过对系统的“观测→识别→推理→决策→控制”过程的反复操作,不断积累经验,总会使后面的操作效果变得更好。这是一个智能性的决策和控制过程。因此,从广义上看,人机系统具有能控性<sup>[83]</sup>。神经网络系统的智能特征使得 NNCS 具有拟人智能控制决策的特点。它象人机系统一样,只要 NNC 的学习是稳定、收敛的,总可以控制一个过程沿目标函数值最优的方向搜索,最终达到期望的目标值要求。因此,NNCS 本质上可以对复杂系统进行有效地控制。从这个意义上说,NNCS 具有能控性。

下面来讨论 NNCS 的稳定性。

在提出的控制结构中,NNC 与常规反馈控制器构成一个有机的整体,共同负责对系统的控制。由于 NNCS 本身是复杂的非线性系统,其动力学特性不能简单用传统的数学工具来进行描述和分析。因此,关于该 NNCS 的稳定性,有以下命题:

**命题 6.1** 对于图 6-1 所示的 NNCS,保证其稳定的充要条件是:

- ① 反馈使制器 FC 对系统的控制是渐近稳定的。
- ② NNC 的学习是稳定、收敛的。

证明:由 6.2 节系统的工作原理知,神经网络控制系统的工作过程分为学习控制期和稳态控制期。

若条件①满足,则在 NNC 学习阶段,FC 能对系统进行渐近稳定控制。在控制过程中,FC 和 NNC 的各输入变量均为有界。若条件②满足,则 NNC 的学习每次必能收敛于一个定解,网络的输出必有界。如系统是连续可控的,则系统是输入输出有界的。当学习过程结束后, $u_f(k)$ 及 $\dot{u}_f(k)$ 均趋于零,NNC 完全收敛,并实现从其输入集  $X$  到系统控制集  $U$  的一个满射,即

$$\text{NNC}: X \rightarrow U \quad (6.19)$$

此时,系统的输出误差  $e(k)$  及  $\dot{e}(k)$  亦为零,NNC 完全代表了系统的逆动力学,并相当于系统的直接逆控制器。充分性得证。

若系统稳定,则对系统误差集  $E$  中的任意  $e \in E$ ,存在  $u \in U$ ,使系统稳定。那么反馈控制器 FC 首先必须是稳定的,且 NNC 对任意  $X_1 \in X$ ,必须能给出定解  $u_n \in U$ ,即 NNC 的学习必须是稳定、收敛的。

证毕。

在本章提出的 NNCS 中,反馈控制器 FC 设计为一比例控制器,通过实验总可以确定一个比例常数使系统渐近稳定;另由定理 2.5 可知,NNC 的学习是全局稳定收敛的,因此本章提出的 NNCS 是能够稳定的。

## 6.4 实验研究

### 6.4.1 控制对象及控制系统设计

控制对象为一电液伺服加载试验系统。该系统是一个典型的时变非线性系统,在控制过程中,系统参数会随着加载过程的变化而产生大范围改变,加之电液伺服系统固有的非线性特性,难以精确建模<sup>[89]</sup>,常规控制方法难以取得满意的控制效果。控制要求是系统能高精度快速跟踪给定的波形,并对外干扰和系统参数变化具有良好的鲁棒性。

为此,我们基于神经网络在线自学习模糊自适应控制方法,设计电液伺服加载试验控制系统,如图 6-5 所示。其中神经网络在线自学习模糊自适应控制器是系统的核心,它和试验波形发生器一起由 NEC433 计算机实现。A/D、D/A 采用 16 位 AX5621 板,以中断方式工作,输入输出信号范围为 $(-10\text{V}, 10\text{V})$ 。

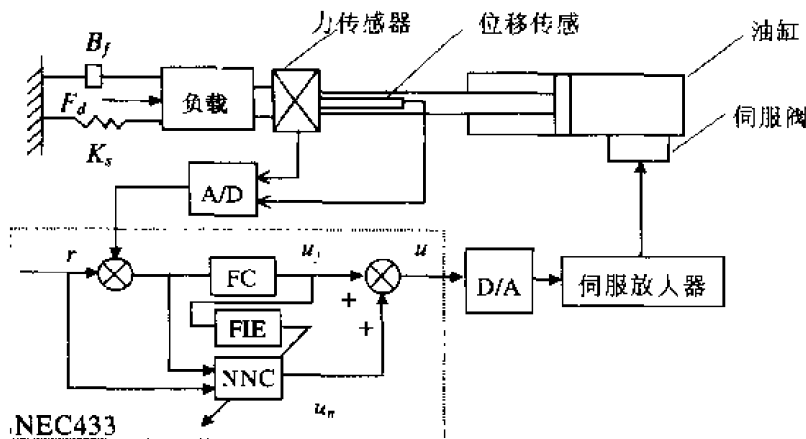


图 6-5 神经网络在线自学习模糊自适应控制系统

实验中,油源压力置为  $10\text{MPa}$ 。

① FC 的设计。FC 的设计原则是保证系统渐近稳定。本处取为比例控制器,且  $K_p = 1.0$ 。

② NNC 的构造。通常,电液伺服系统是一个二至三阶系统,因此设计神经网络控制器 NNC 时,取  $m = 3$ ,即可反应系统的特性,故神经模型输入层选取 4 个单元。隐层单元数由仿真试验确定,本例中发现 5~30 个隐单元均能取得较好的效果,且隐单元个数除对收敛速度稍有影响外,对跟踪误差并非特别敏感。由于本结构中,NNC 是在线动态调整的,不必将隐单元个数设置过多,以利于缩短网络在每一采样周期中的训练时间,实验选取 6 个。不失一般性,网络的初始权值在  $(-0.1, 0.1)$  区间内随机选取,其他训练参数分别设置为  $\lambda_0 = 0.35$ 、 $\mu = 0.5$ 、 $\alpha = 0.65$ 、 $\varepsilon = 10^{-3}$ 、 $K_{u_f} = 0.3$ 、 $K_{\dot{u}_f} = 0.5$ 、 $K_\delta = 3.0$ 。

假定系统对 NNC 来说是未知的,即 NNC 不经过事先训练,直接根据 FC 对系统实施控制时的实时测量信息,在线学习系统逆动力学。

另外,神经元采用的 sigmoid 激活函数的取值范围为  $(-1, 1)$ ,为确保 NNC 的逼近精度,在参考信号和反馈信号送入 NNC 之前,进行归一化处理。

### 6.4.2 实验结果

实验装置如图 4-8 所示,负载对象为板簧-小车系统,板簧刚度未知,且呈不确定非线性变化。

图 6-6 和图 6-7 给出了不同幅值和频率下正弦波跟踪控制结果。可以看出,神经网络控制器经过有限次在线学习后,可对系统实施良好的控制,并对板簧引入的不确定性具有良好的适应能力。




图 6-6 4Hz 正弦波跟踪控制结果




图 6-7 2Hz 正弦波跟踪控制结果

为了比较控制算法的优劣,我们采用反馈误差学习法对系统实施控制,NNC 的权值调整规则采用(6.4)式进行,学习率取为  $\eta = \lambda_0 / (1 + E)$ 。图 6-8 和 6-9 给出了基于直接反馈误差学习法的控制结果。

比较图 6-6 和图 6-8 及图 6-7 和图 6-9,可以看出,在 NNOLFAC 方法中,由于 NNC 采用模糊推理机产生的分目标学习误差进行训练,跟踪结果更加平稳,特别是在初始控制阶段,系统的超调量明显降低。

另外,由图中可以看出,在稳态跟踪期,图 6-6 和图 6-8 的跟踪效果明显优于图 6-7 和图 6-9 的跟踪效果。可见,在进行大位移跟踪时,由于板簧的变形较大,板簧刚度的非线性变化对系统控制性能的影响也较大。




图 6-8 基于反馈误差学习法的跟踪控制结果




图 6-9 基于反馈误差学习法的跟踪控制结果

## 6.5 本章小结

本章针对工业系统中普遍存在的复杂非线性和时变不确定性特性,提出了一种神经



网络在线自学习模糊自适应控制结构,并对 NNC 的在线学习进行了研究。

(1)该方法采用反馈误差学习法,不仅做到无须辨识被控对象的模型,即可进行 NNC 的在线设计;而且,NNC 的学习过程和系统的控制过程同时进行,不需要特定的教师信号,避免了离线训练通常存在的训练数据不足的问题。

(2)NNC 利用模糊推理机产生的分目标学习误差进行训练,避免了采用直接反馈误差进行训练可能造成的饱和和过调整问题,并能有效抑制测量噪声的影响,提高系统的控制品质。

(3)在反馈通道引入控制器 FC,起到了监督控制的作用,不仅增强了神经网络控制策略的完备性,使整个控制系统具有良好的稳定性和鲁棒性,而且在系统受到干扰时,通过 FC 的反馈补偿作用,能有效提高系统的精度和自适应能力。

实验证明,该方法能有效处理工业系统中普遍存在的复杂非线性和时变不确定性等特性,实现对电液伺服系统的高精度平稳跟踪。控制效果明显优于传统反馈误差学习控制方法。为未知不确定非线性系统的智能控制提供了一条有效而可行的新途径。

## 第七章 基于神经网络辨识模型的 在线迭代学习控制

### 7.1 引言

第三章中,我们讨论了神经网络辨识问题,可以看出,神经网络所具备的非线性映射特性和高度的并行运算能力,可以快速实现对任意非线性函数的逼近。利用神经网络这种强大的函数逼近能力,可以方便地从系统的测量信息中学习系统的输入输出特性,而无须太多的有关逼近对象的结构、特征等方面的先验知识。这一点为系统辨识,尤其是非线性动态系统的辨识,提供了一条十分有效的途径。

从控制角度看,神经网络辨识在系统控制中所起的作用是:

- ①参数辨识,为控制律的构造提供系统的参数信息。
- ②函数辨识,将系统视为一个未知的时变函数,由辨识网络构造出一个已知结构和参数的数学模型——也相当于系统的一个物理实现。

神经网络用于系统的参数辨识可以对未知结构的非线性系统来进行,放松了传统参数辨识方法中要求系统线性、定常、结构已知的限制条件<sup>[18,206]</sup>。而用于函数辨识可以直接针对动态系统来进行,这种方法在目前神经网络辨识与控制中应用较多,它包括对系统正向模型的辨识和逆模型的辨识。逆模型辨识要求系统可逆。同时,为了得到系统完备的离线模型,还要求具备持续激励的条件,即输入信号必须充分激励系统的所有模态,这一点与线性系统辨识类似。当系统不具备持续激励条件时,神经网络模型的离线学习训练就难以完成。

在控制研究中,通常采用神经网络在线实时辨识与另一个神经网络控制器共同作用的方式,构成一种间接神经网络控制结构<sup>[81,170,171]</sup>。这种结构相当于一种内模控制<sup>[192]</sup>,神经网络辨识的目的是为控制器权值的调整提供系统的 Jacobi 矩阵,即  $\partial y / \partial u$ 。在理论上,我们认为,如果存在一个收敛的神经网络辨识权值  $W_{NNI}$  和神经网络控制器权值  $W_{NNC}$ ,能够保证系统均方收敛或  $L_2$  收敛,那么当辨识网络收敛到  $W_{NNI}$ 、控制器网络收敛到  $W_{NNC}$  时,系统控制收敛。但在实际工程中,这仅仅是控制系统收敛的一个充分条件,而非必要条件。实际的情况是,当控制收敛时,辨识网络和控制网络权值收敛但并非惟一。收敛结果与初始权值的选择、控制信号形式息息相关。这一点与传统辨识意义上的参数惟一收敛不同。这是神经网络在线辨识控制中通常存在的情况。

我们知道,控制的目的是保证系统输出收敛,而非辨识网络、控制网络权值惟一收敛。当然,后者惟一收敛的确能够保证控制系统收敛到一个较好的程度,且可能具备较强的泛化能力。但是对单一目的的控制任务而言,网络权值惟一收敛并不是必需的。这一点似乎常常被忽略。另外,实际控制对系统输出收敛的要求也是因控制对象而异,只要满足一定的条件就可以了。一味追求零误差收敛既不现实,也没有必要。需要强调的是,在工程应用中,神经网络在线辨识由于受到采样时间的限制,辨识网络很难在一个采样周期内产

生收敛,尤其在控制初期,网络对系统的了解甚少,很难做到立即收敛。这给控制量的求解带来了困难。通常的解决办法是,选择合适的网络和学习算法,保证系统辨识沿时间轴收敛。即在每个采样周期内,给定循环训练次数,使网络辨识逐步向收敛状态逼近,同时保证网络不发散。虽然,此时根据可能还未收敛的辨识网络求得的控制量不能保证系统“立即”到达期望轨迹,但在理论上只要辨识最终收敛,控制也会最终收敛<sup>[84]</sup>。因此,我们可以根据模型在线提供的大致准确的系统信息,直接构造控制律。这一点与迭代学习控制的思想非常相似,其诱人之处在于控制量可直接形成,控制律简单。

根据上述思想,本章在神经网络辨识的基础上,提出了基于神经网络辨识的模型参考递推控制方法,构造了神经网络在线迭代学习算法,并通过数字仿真研究证明了提出的方法是有效的。

## 7.2 基于神经网络辨识的模型参考递推控制原理

在系统控制中,神经网络辨识模型不仅能提供系统的参数信息,而且可提供系统的函数信息,如系统的 Jacobi 矩阵。因此,只要能获得系统的神经网络模型,就可以将该模型视为系统的一个物理实现(更确切地说是数字实现),控制器的设计即可直接针对该模型进行操作了。神经网络模型可以是离线训练好的,也可以是在线实时训练的。

特别的,对动态递归网络,它不仅能够辨识系统的函数,而且可获得系统的导数信息。如对 SISO 系统,选用单输入单输出动态递归网络,就可以直接求得系统的一阶导数信息。那么在给定参考模型期望轨迹和神经网络辨识模型的情况下,系统的期望控制量就可以由增量式算法直接递推求解,而不必再构造一个神经网络控制器,通过权值调整来获得控制量<sup>[77]</sup>。

为研究问题方便,考虑如下的离散 SISO 非线性系统:

$$y(k+1) = f[y(k), \dots, y(k-n+1), u(k), \dots, u(k-m+1)] \quad (7.1)$$

其中:  $y(k) \in R^n$ ,  $u(k) \in R^m$  分别为系统的输出和输入;  $f(x)$  为未知非线性函数。

给定期望轨迹可以是已知的非线性方程,也可以是线性方程。不失一般性,我们用如下的线性方程来描述:

$$y_m(k+1) = A_m y_m(k) + B_m u_m(k) \quad (7.2)$$

其中

$$A_m(z) = a_0 + a_1 z^{-1} + \dots + a_{n-1} z^{n-1}$$

$$B_m(z) = b_0 + b_1 z^{-1} + \dots + b_{m-1} z^{m-1}$$

控制任务是寻找控制量  $u(k)$ , 使得

$$\lim_{k \rightarrow \infty} \|y_m(k) - y(k)\|_{u(k)} = 0 \quad (7.3)$$

为此先作如下假设:

**假设 7.1** 控制是可达的,对非线性方程(7.1),当  $y(k) = y_m(k)$  时可解。即存在某个控制区域  $D$ ,  $\forall \epsilon > 0$ , 存在  $u \in D$ , 使

$$\|y(k+1)|_u - y_m(k)\| < \epsilon \quad (7.4)$$

成立。

**假设 7.2** 非线性系统(7.1)式连续且满足局部 Lipschitz 条件,即有

$$\|f[y_0(k), u_1(k)] - f[y_0(k), u_2(k)]\| \leq f_1 \cdot \|u_1(k) - u_2(k)\| \quad (7.5)$$

$$\|f[y_1(k), u_0(k)] - f[y_2(k), u_0(k)]\| \leq f_2 \cdot \|y_1(k) - y_2(k)\| \quad (7.6)$$

其中:  $f_1 > 0, f_2 > 0$  是 Lipschitz 常数,  $y_0(k), y_1(k), y_2(k), u_0(k), u_1(k), u_2(k)$  为系统的输出、输入信息。

**假设 7.3** 存在神经网络

$$y_n(k+1) = NN_f(W, X(k)) \quad (7.7)$$

能在给定精度上,完全逼近(7.1)式描述的非线性系统。即  $\forall \varepsilon > 0$ , 存在权值  $W$ , 使得  $X(k) \in R^{n+m}$  时, 有下式成立

$$\|NN_f(W, X(k)) - y(k+1)\| < \varepsilon \quad (7.8)$$

且  $y_n$  对系统输入  $u$  的偏导数存在, 即

$$y'_n = \frac{\partial y_n}{\partial u} = NN'_f(W, X) \quad (7.9)$$

根据以上假设, 当已知期望的控制轨迹时, 则可以由欧拉法、中点法等直接推导出系统的控制量。将(7.7)式对控制  $u$  进行 Taylor 展开

$$y_n(k+1) - y_n(k) = [u(k) - u(k-1)] \cdot NN'_f[W, X(k-1)] + 0[u(k) - u(k-1)]^2 \quad (7.10)$$

当

$$y_n(k+1) = y_m(k+1) \quad (7.11)$$

时, 由欧拉法可得系统的输入控制量为

$$\begin{aligned} u(k) &= u(k-1) + \frac{y_m(k+1) - y_n(k)}{NN'_f(k-1)} \\ &= u(k-1) + \frac{NN'_f(k-1)}{\varepsilon + NN'_f(k-1)NN'_f(k-1)} [y_m(k+1) - y_n(k)] \end{aligned} \quad (7.12)$$

其中  $\varepsilon > 0$  是为防止  $NN'_f(k) = 0$  而取的小正数。

另外, 由中点法也可求出系统的控制输入为

$$u(k) = u(k-2) + \frac{NN'_f(k-1)[y_m(k+1) - y_n(k-1)]}{\varepsilon + NN'_f(k-1)NN'_f(k-1)} \quad (7.13)$$

以上两式说明, 在给定参考模型期望轨迹和神经网络辨识模型时, 就可以由一些传统的方法如欧拉法、中点法等增量式算法直接求出系统的期望控制量。这使得控制器的设计变得简便, 惟一的要求是知道未知系统的辨识模型对控制输入的导数信息。图 7-1 给




图 7-1 基于神经网络辨识的模型参考递推控制原理

出了基于神经网络辨识的模型参考递推控制原理框图。

上述控制策略的关键是神经网络模型的辨识。若模型的精度足够高,且对控制量  $u$  的导数可求,则构造的控制律可实现对任意期望轨迹的跟踪。

在对未知动态系统的跟踪控制中,为提高模型的辨识精度,可以采用 3.4 节提出的神经网络在线自适应跟踪辨识方法。我们知道,虽然系统中的非线性是绝对的,但对大多数受控的非线性系统而言,我们都能够找到一个线性系统与之对应,而不论这个线性系统有多粗糙。或者说该非线性系统可视为一个线性系统和一个非线性环节的叠加,我们可称之为弱非线性系统或局部非线性系统。如果将这类非线性系统的输入/输出关系“归划”到包含这个线性系统的某一映射空间中,那么系统的非线性就会被“压缩”到一个比较小的区间上。可见,辨识一个系统的非线性环节要比辨识原系统容易得多。相应的,神经网络的搜索空间将大大缩小,有利于提高收敛速度。这一点与 3.4 节的分析是一致的。

因此,对于弱非线性系统或者局部非线性系统,为了提高神经网络辨识效率,在假设 7.3 的条件下,我们给出如下假设:

**假设 7.4** 对系统(7.1),存在一个低阶的线性估计模型:

$$y_{m1}(k+1) = A_{m1}y_{m1}(k) + B_{m1}u(k) \quad (7.14)$$

和动态递归神经网络 DRNN

$$y_n(k+1) = NN_f(W, X(k)) \quad (7.15)$$

在相同的输入下,  $\forall \epsilon > 0$ , 有下式成立

$$\| NN_f(W, V, u(k)) + y_{m1}(k+1) - y(k+1) \| < \epsilon \quad (7.16)$$

根据假设 7.4,神经网络模型只须辨识原系统与一个低阶线性系统的差即可,运算量大大减少,有利于增强神经网络辨识的实时性。辨识算法可采用 2.2.3 节的 BP 学习算法,辨识结构如图 7-2 所示。




图 7-2 神经网络辨识结构

神经网络辨识完毕后,可由动态递归网络结构,直接求出网络的导数为

$$\frac{\partial y_n(k+1)}{\partial u(k)} = NN'_f(W, u(k)) = NN'_f(k) \quad (7.17)$$

至此,就可以求出系统模型  $(y_{m1} + y_n)$  对控制量  $u$  的导数,从而可按(4.12)式或(4.13)式构造递推控制律。

## 7.3 神经网络在线迭代学习控制算法

### 7.3.1 迭代学习控制原理

在过程控制中,存在着一种单一过程是非线性运动,但又多次重复发生的行为。如机器人搬运工件,虽然机器人每次搬运都是多自由度的非线性过程,但是这种行为又多次重复发生,而且每次重复轨迹一致,在初始条件相同时,每次运动轨迹可能完全一致。还有零件的批量加工,每个零件的加工过程是完全一样的。由此,Uchiyam 提出了迭代学习的思想,后经 Arimoto 等人加以完善,建立了实用的控制算法<sup>[207,208]</sup>,特别适合机器人等重复运动的控制场合。对于非线性、强耦合、难以建模以及高精度轨迹跟踪控制问题,迭代学习控制提供了一个简单实用的控制思路。其基本原理如图 7-3 所示,在控制过程循环中,每个采样时刻的控制误差都用来修正下次循环的控制量。

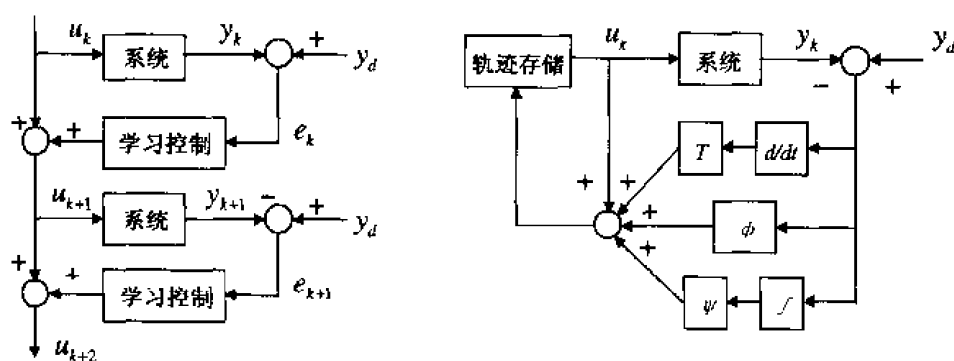


图 7-3 迭代学习控制原理

迭代学习控制的核心是基于系统不变性的假设。系统的控制过程本质上是通过重复学习而逐渐逼近系统逆模型的过程。随着迭代学习控制理论的发展与完善,人们提出了许多简单实用的迭代学习控制算法<sup>[209-212]</sup>,其中较具典型的有开、闭环 PID 迭代学习算法。

开环 PID:

$$u_{k+1}(t) = u_k(t) + \alpha e_k(t) + \beta \frac{de_k(t)}{dt} + \gamma \int e_k(t) dt \quad (7.18)$$

闭环 PID:

$$u_{k+1}(t) = u_k(t) + \alpha e_{k+1}(t) + \beta \frac{de_{k+1}(t)}{dt} + \gamma \int e_{k+1}(t) dt \quad (7.19)$$

其中:  $e_k(t)$  为上次控制误差;  $e_{k+1}(t)$  本次循环控制误差;  $\alpha, \beta, \gamma$  为 PID 控制参数。文献 [12] 进一步将时域中的迭代学习控制理论和频域中的基于同一控制思想的重复控制理论进行了统一的描述,提出了异步自学习控制的理论框架。目前,国内外学者虽然在迭代学习控制的理论研究上作了不少工作,如进行二维分析<sup>[209]</sup>、初始条件对迭代学习影响的研究以及如何克服系统时滞影响的研究等<sup>[213,214]</sup>。但随着系统理论的发展,迭代学习控制中存在的问题也愈显突出,如将系统完全作为黑箱处理而未利用可能得到的系统信息。

因此,如何与其他控制策略相结合,以便放宽应用条件,拓展迭代学习的应用领域,是迭代学习控制研究应把握的方向。这是因为一门好的理论与技术的出现,其价值应最终体现在实际应用中。日本在这方面的做法值得借鉴,如日本是最早将迭代学习控制应用于非圆工件加工的。近年来,我国学者也将迭代学习控制与自适应控制技术相结合,用来解决高精度曲面加工问题<sup>[215]</sup>。这些应用研究又进一步促进了迭代学习控制理论的发展与完善。

### 7.3.2 神经网络在线迭代学习控制算法及收敛性分析

对(7.12)式和(7.13)式求出的控制量,其控制效果只有在下一时刻才能看到。事实上,我们知道,由于神经网络求得的系统导数信息是有差的,即辨识模型有差,因此由欧拉法和中点法求解的控制量自然是有差的。即使在辨识完全准确的情况下,(7.12)式的控制量也会由于近似计算而存在误差。因此受迭代学习控制思想的启发,我们将求得的控制量输入神经网络模型,由网络输出与期望模型输出之差进一步迭代求解控制律。当系统的神经网络模型已知时,每一时刻控制量的求解可以视为一个单独的循环周期,求解过程仅针对神经网络模型进行。设  $k$  代表采样时刻,  $j$  是采样时间内控制量的迭代循环次数。可见,这里存在二维空间的时间轴,其一是控制时间轴,或称采样时间意义上的离散点;其二是每个采用周期内的迭代循环次数,也可以认为是离散的时间轴。

根据上述思想,神经网络迭代学习算法可以构造为:

$$\begin{cases} u(k, j+1) = u(k, j) + \eta[y_m(k+1) - NN_f(k, j)] * [NN'_f(k, j)]^{-1} \\ u(k, 0) = u(k-1) \end{cases} \quad (7.20)$$

其中  $\eta > 0$  为迭代学习因子。

对(7.20)式的神经网络迭代学习算法的收敛性,我们给出如下定理。

**定理 7.1** 非线性系统(7.1)式采用(7.20)式的学习控制算法,能够保证神经网络辨识模型的输出收敛到期望轨迹上。

证明:定义  $k$  时刻,经  $j+1$  次迭代后,神经网络模型的跟踪误差为

$$e(k+1, j+1) = y_m(k+1) - NN_f(k, j+1) \quad (7.21)$$

假设神经网络模型  $NN_f(W, u)$  连续,且一阶导数存在,则根据中值定理,  $\forall u_1, u_2 \in D, \exists u_0 \in [u_1, u_2]$  使下式成立

$$NN_f(W, u_1) - NN_f(W, u_2) = (u_1 - u_2) NN'_f(W, u_0) \quad (7.22)$$

将(7.22)式代入(7.21)式,得

$$\begin{aligned} e(k+1, j+1) &= y_m(k+1) - NN_f(W, u(k, j+1)) \\ &= e(k+1, j) - [NN_f(W, u(k, j+1)) - NN_f(W, u(k, j))] \\ &= e(k+1, j) - (u(k, j+1) - u(k, j)) NN'_f(W, \bar{u}(k)) \end{aligned} \quad (7.23)$$

其中  $\bar{u}(k) \in [u(k, j), u(k, j+1)]$ 。将(7.20)式代入上式得

$$e(k+1, j+1) = \left[ 1 - \frac{\eta NN'_f(W, \bar{u}(k))}{NN'_f(W, u(k, j))} \right] e(k+1, j) \quad (7.24)$$

可见,当

$$\left| 1 - \eta \frac{NN'_f(W, \bar{u}(k))}{NN'_f(W, u(k, j))} \right| < 1 \quad (7.25)$$

时,有

$$\lim_{j \rightarrow \infty} e(k+1, j) = 0 \quad (7.26)$$

也就是说,当(7.25)式成立时,能够找到某一控制量  $u(k)$ ,使得神经网络模型的输出收敛到期望轨迹上:

证毕。

**定理 7.2** 非线性系统(7.1)采用(7.20)式的学习算法求解控制量,能够保证系统的输出收敛到期望模型的输出。

证明:由假设 7.3 可知,  $\forall \varepsilon_1 > 0$ , 存在网络权值  $W$ , 使得当  $u \in D$  时, 有

$$\|NN_f(W, u) - y\| < \varepsilon_1 \quad (7.27)$$

而由定理 7.1 知,  $\forall \varepsilon_2 > 0, \exists u \in D$ , 使下式成立

$$\|NN_f(W, u) - y_m\| < \varepsilon_2 \quad (7.28)$$

则

$$\|y_m - y\| \leq \|y_m - NN_f\| + \|NN_f - y\| < \varepsilon_1 + \varepsilon_2 = \varepsilon \quad (7.29)$$

即控制系统的输出可以收敛到期望模型的输出。

证毕。

由定理 7.1 和定理 7.2 可以得出,如果能够得到非线性系统精确的神经网络辨识模型,并采用迭代算法直接求解控制量,则可以实现对期望轨迹的任意精度跟踪。

定理 7.1 和定理 7.2 给出的结论都基于一个基本假设,即辨识网络已收敛,且迭代学习次数可以趋于无穷。然而,在动态辨识和实时控制时,神经网络在线辨识和控制算法的迭代学习时间要受到采样时间的限制,这些必须在一个采样周期内完成。而实际上,辨识网络的输出误差在一个采样时间内很难收敛到零,尤其是在训练初始,网络对系统了解甚少,甚至不具备任何信息记忆,很难做到辨识过程立即收敛,这给控制量的求解带来了困难。另一方面,即使神经网络模型已经收敛,控制量的迭代学习过程能否在一个采用周期内产生收敛也是个问题。为保证控制的实时性,必须对辨识次数和迭代学习次数加以限制。这样必然存在神经网络模型的辨识误差  $\text{Iden}_e(k)$  和迭代学习截断误差  $\text{Pre}_e(k)$ 。在这种条件下,如何保证系统的快速收敛和全局收敛特性? 迄今尚未见诸报道。对此我们提出两种解决途径,一是采用双 CPU 工作方式,其中一个 CPU 用于实时系统辨识,另一个 CPU 间断利用辨识结果(训练权值)求解控制量;二是选择合适的网络和学习算法,保证系统辨识沿时间轴收敛,并在每个采样周期内,给定控制量的迭代学习次数,使学习过程逐步向收敛状态逼近,同时保证控制量的迭代学习不发散。此时,虽然根据可能还未收敛的辨识网络求得的控制量不能保证系统“立即”到达期望轨迹,但在理论上只要辨识过程最终收敛,控制也会最终收敛<sup>[84]</sup>。

此外,为加快控制量的迭代收敛,可以用神经网络模型的辨识误差对控制量迭代算法进行修正。假设在每个采样时刻,  $NN_f$  的辨识次数是  $N_1$ , 收敛误差为  $\text{Iden}_e(k)$ , 则系统的实际输出为

$$y(k) = NN_f(W, V, u(k-1)) + \text{Iden}_e(k) \quad (7.30)$$

如果该辨识误差不变地传播到控制量的迭代计算中,则(7.20)式可修正为

$$u(k, j+1) = u(k, j) + \eta \frac{y_m(k+1) - NN_f(k, j) - \text{Iden}_e(k)}{NN'_f(k, j)} \quad (7.31)$$



同样,当控制量的迭代学习次数定为  $j \leq N_2$  时,则有迭代学习截断误差  $\text{Pre-}e(k)$ ,该误差也应加权修正后叠加到控制量上。类似于比例控制,选取加权系数为  $K_p$ ,则控制量可修正为

$$u(k+1) = u(k, N_2) + K_p \text{Pre-}e(k) \quad (7.32)$$

下面给出 SISO 系统的控制设计步骤。为完整起见,将问题重新阐述如下。设:

参考模型:  $y_m(r+1) = A_m y_m(k) + B_m u_m(k)$ ;

参考输入:  $u_m(k)$ ;

线性化模型:  $y_{m1}(k+1) = a_1 y_{m1}(k) + b_1 u(k)$ ;

动态递归网络:  $y_n(k+1) = \text{NN}_f(W, u(k))$ 。

控制目的是产生控制量  $u$ ,使系统输出  $y(k+1) = y_m(k+1)$ 。

综合以上分析,基于神经网络辨识的在线迭代学习控制算法的实现步骤如下:

①在  $k$  时刻,对系统进行采样得到  $y(k)$ ,计算神经网络模型输出和给定线性系统输出,并根据误差  $y(k) - (y_{m1}(k) + y_n(k))$ ,由 BP 算法调整  $\text{NN}_f$  权值,学习次数限制为  $N_1$  次。

②计算  $u_m(k)$ ,并求参考模型的输出  $y_m(k+1)$ 。

③计算神经网络模型对输入的导数  $\text{NN}'_f(W, u(k-1))$ 。

④由(7.31)式计算控制量  $u(k, j)$ ,并求  $y_{m1}(k, j), \text{NN}_f(k, j)$ 。

⑤计算迭代学习截断误差  $\text{Pre-}e(k) = y_m(k+1) - y_{m1}(k, j) - \text{NN}_f(k, j)$ ,若  $|\text{Pre-}e(k, j)| > \varepsilon_2$  且  $j < N_2$ ,则  $j = j + 1$ ,转步骤④。

⑥令  $k = k + 1$ ,对  $y(k)$  和  $u(k)$  进行移位处理,返回步骤①。

## 7.4 仿真研究

仿真实例一:

考虑非线性系统

$$y(k+1) = 0.5y(k) + 0.5 \frac{y^2(k-1)}{1+y^2(k-1)} - 0.5y(k-1)u(k) + u(k) \quad (7.33)$$

取期望轨迹模型为

$$y_m(k+1) = 0.6y_m(k) + 0.4u_m(k) \quad (7.34)$$

线性估计模型为

$$y_{m1}(k+1) = 0.5y_{m1}(k) + 0.5u(k) \quad (7.35)$$

给定输入是含倍频的正弦信号

$$u_m(t) = 0.5\sin(2\pi ft) + 0.5\sin(4\pi ft) \quad (7.36)$$

图 7-4 给出了 0.1Hz 时系统开环控制的结果。由图可见,系统的跟随误差较大。

本节采用基于神经网络辨识的在线迭代学习控制算法对上述系统进行控制。设动态递归 DRNN 神经网络结构为  $(1+6) \times 6 \times 1$ ,网络初值权值取  $(-0.25, 0.25)$  之间的随机数;隐节点输出初值为零,隐层单元激活函数为对称型 Sigmoid 函数,网络输出层为线性单元,输出层权值的调节采用 LPIDBP 算法。采样周期定为 10ms,辨识和控制误差门限误差均设为 0.01。




图 7-4 系统的开环响应

为避免控制初期由于神经网络辨识模型不准确而可能产生的系统振荡,在控制开始的前 0.1 秒内,神经网络模型仅参与系统辨识,系统控制量由参考模型的输入信号和系统输出误差直接反馈信号组成。0.1 秒后再采用基于神经网络辨识结果的迭代学习控制律。图 7-5 给出了这种情况下神经网络闭环控制的结果。比较图 7-4 与图 7-5 控制误差曲线可见,基于神经网络辨识的在线迭代学习控制策略是成功的,可以实现对低频信号的稳态无差跟踪。




图 7-5 神经网络迭代学习控制结果

仿真实例二:

控制对象为非线性电液伺服弹簧质量系统,其状态方程如(3.29)~(3.31)式所示,各物理量及参数如表 3-1 所示。

设参考模型为二阶系统,传递函数为:

$$G(s) = \frac{y_m(s)}{u_m(s)} = \frac{900}{s^2 + 62s + 900} \quad (7.37)$$

取参考输入为

$$u_m(t) = 0.002 + 0.0015\sin(\omega t) \quad (7.38)$$

将参考输入信号作用于给定的参考模型和阀控缸电液伺服弹簧质量系统,其输出响应如图 7-6 所示。可见,系统的跟踪输出与参考模型的期望输出在幅值和相位上均有较大差异。




图 7-6 系统开环响应曲线

本节利用 3 种神经网络模型,采用基于神经网络辨识的迭代学习控制方法对上述系统进行控制。

3 种神经网络模型分别为 BP 网络、Elman 网络和 CIDRNN 模型。其中 BP 网络结构为  $6 \times 5 \times 1$ ,网络初始权值在  $(-0.5, 0.5)$  之间随机选取;Elman 网络结构为  $1 \times 6 \times 1$ ,网络初始权值在  $(-0.2, 0.2)$  之间随机选取,反馈系数为 0.65;复合输入动态递归神经网络 CIDRNN 模型结构为  $(1+5) \times 5 \times 1$ ,网络初始权值在  $(-0.25, 0.25)$  之间随机选取,自反馈系数设为 0.25,反馈系数为 0.5,前馈滤波系数为 0.9。另外,Elman 网络和 CIDRNN 模型隐层单元初值均取为零值。

辨识方法采用第二章提出的神经网络在线自适应跟踪辨识方法,辨识算法采用标准 BP 算法,学习率设为 0.01,每一采样周期内的辨识次数为 100 次,相对辨识精度定为 5%。

控制算法采用神经网络在线迭代学习控制算法。迭代学习因子定为 0.02,每一采样周期内控制量的迭代学习次数设为 50 次,相对控制精度定为 5%。系统采样周期设为 0.01 秒。

考虑到系统的期望跟踪量较小,为提高控制精度,辨识信号和控制信号在使用前均作归一化处理。

图 7-7~7-9 给出了  $\omega = 3\text{rad/s}$  时,基于上述 3 种网络模型辨识的在线迭代学习控制结果,其中的虚线为参考模型的输出。可以看出,各网络模型均能较好的实现对电液伺服弹簧质量系统的跟踪控制。从收敛时间上看,CIDRNN 模型具有明显的优势,BP 网络相对较差。




图 7-7  $\omega = 3\text{rad/s}$  时基于 BP 网络的控制曲线




图 7-8  $\omega = 3\text{rad/s}$  时基于 Elman 网络的控制曲线




图 7-9  $\omega = 3\text{rad/s}$  时基于 CDRNN 网络的控制曲线

改变输入信号的频率,当  $\omega = 6\text{rad/s}$  时,基于各网络模型的在线迭代学习控制结果如图 7-10~7-12 所示。由图可知,BP 网络在高频输入时,难以跟踪系统的动态,基于 Elman 网络的迭代学习控制也存在一定的静差,相比之下,CIDRNN 模型的综合控制功能较强,基本做到了对参考模型输出的无差跟踪。




图 7-10  $\omega = 6\text{rad/s}$  时基于 BP 网络的控制曲线




图 7-11  $\omega = 6\text{rad/s}$  时基于 Elman 网络的控制曲线




图 7-12  $\omega = 6\text{rad/s}$  时基于 CIDRNN 网络的控制曲线

## 7.5 本章小结

本章基于动态神经网络辨识,根据迭代学习控制思想,提出了基于神经网络辨识的模型参考间接自适应控制方法,控制量由神经网络模型的输出跟踪误差和模型的导数信息通过迭代学习直接生成,控制策略简单,实现方便。理论分析表明,如果神经网络模型具有足够高的辨识精度,控制系统可实现对任意轨迹的高精度跟踪。本章还针对工程控制中,神经网络模型存在的辨识误差,提出了辨识误差补偿控制方法。仿真研究表明,提出的基于神经网络辨识的控制方法具有良好的控制品质。

## 第二篇 应用与实现

### 第八章 电液伺服板簧试验系统的神经网络 自适应控制

#### 8.1 引言

板簧是汽车悬架中采用的一种弹性减振元件,又称钢板弹簧。它将车架与车轴弹性地连接起来,可以缓和路面对车身的冲击,衰减冲击载荷引起的承载系统的振动<sup>[117,118]</sup>。因此,钢板弹簧机械特性的研究对汽车性能的改进显得非常重要。虽然,随着科学技术的发展,主动减振及半主动减振等措施已用于汽车的减振控制中,但从安全和实用角度,目前还不能完全抛开板簧减振装置。

对板簧的研究通常包括两个方面,一是设计研究,二是动态特性研究。由于板簧是多片钢片组合而成,因此其设计研究的主要任务是如何计算刚度和各簧片的工作应力,属于静态特性研究,内容主要包括刚度应力模型的建立、有限元分析及相应的计算方法等<sup>[216,217]</sup>。对板簧动态特性的研究主要是定性地分析加振频率、加振振幅及额定静载荷对弹簧刚度和能量耗散特性的影响。动态特性研究大都是在电液伺服试验机上进行的。随着汽车工业的发展,国内外许多学者都很重视板簧动态特性的研究<sup>[218]</sup>,但存在的缺陷是,致力于板簧特性研究的人大多只关心板簧的力学性能,如采用有限元分析板簧的动态刚度和片间阻尼等;而进行电液伺服系统研究的人在系统分析中则仅考虑了线性弹簧质量负载的情况。从工程应用的角度看,二者都是不全面的。因此,如何从系统角度,将两者结合起来进行研究,无论对板簧设计还是电液伺服系统的研究都会开辟一个新的思路,尤其是对现代电液伺服控制技术的发展将具有深远的意义。

板簧由多层钢板叠合而成,刚度是渐变的,运动中存在摩擦(库仑)和阻尼,因此弹簧力与变形特性是非线性关系。在正弦振动中,各部分的加速度也不尽相同,惯性力与加速度之间也呈非线性关系<sup>[218]</sup>。加之以电液伺服系统本身固有的非线性因素,如油温、阀开口死区等的影响,使得整个电液伺服板簧系统具有很强的非线性特征。给板簧动态特性的研究带来了困难。如传统的试验方法已不能满足板簧试验的需要。此外,对于线性时不变系统,其稳定性问题已经得到了完善的解决,而非线性系统的稳定性分析则是一个艰难的任务。对非线性板簧试验系统,这一问题不解决,系统的其他品质指标也就无从谈起。鉴于上述情况,本章首先基于范数空间理论,对板簧电液伺服系统进行稳定性分析和设计,然后采用神经网络自适应控制方法,实现对板簧试验系统的高精度控制。

## 8.2 电液伺服板簧试验系统的数学描述

电液伺服板簧试验系统原理如图 8-1 所示,主要由液压油源、信号发生器、控制器及电液执行机构等组成。




图 8-1 电液伺服板簧试验系统原理图

为研究问题方便,将钢板弹簧与伺服油缸分开考虑,系统中各模块的运动方程或平衡方程列写如下:

伺服阀流量方程:

$$Q_L = K_{xv} x_v \sqrt{P_s - P_L \operatorname{sgn}(x_v)} \quad (8.1)$$

油缸流量方程:

$$Q_L = \frac{v_L}{4\beta_e} \dot{P}_L + C_L P_L + A \dot{x}_p \quad (8.2)$$

油缸活塞受力方程:

$$A P_L = m_1 \ddot{x}_p + B_1 \dot{x}_p + f_0 + F \quad (8.3)$$

板簧的受力方程:

$$F = f(\dot{x}_p, \dot{x}_p, x_p) \quad (8.4)$$

其中:  $x_v$  为伺服阀阀芯位移;  $x_p$  为油缸活塞位移;  $m_1$  为活塞杆质量;  $f_0$  为伺服油缸库仑摩擦力;  $F$  为力传感器输出力; 也是板簧的驱动力;  $m$  为板簧质量;  $B_1$  为运动阻尼;  $P_L$  是负载压力;  $P_s$  是系统油源压力;  $K_{xv}$  为伺服阀流量压力系数;  $C_L$  为泄漏系数。

与一般的线性弹簧质量负载不同, (8.4) 式表示的板簧受力  $F$  与活塞位移  $x_p$  是非线性关系, 因此, (8.4) 式与 (8.3) 式不能简单地合并。理论上, 非线性弹簧质量系统可以用如下形式来描述<sup>[7,219]</sup>:

$$m \dot{x} + k_1 x + k_2 x^3 = 0 \quad (8.5)$$

$$m \dot{x} + b \dot{x} + k x + k x^3 = 0 \quad (8.6)$$

$$m \dot{x} + x^2 \dot{x} + x^2 = 0 \quad (8.7)$$

$$m \dot{x} + c \dot{x} + a x + b x^3 = 0 \quad (8.8)$$

其中 (8.8) 式即是著名的 Duffen 方程。

通常, 对板簧而言, 采用精确的动态数学描述相当困难, 而静态方程大多是通过数值拟合并由实验确定的, 难以很好地刻划工作点上的回环特性。



在方程(8.4)中,力  $F$  由迟滞恢复力  $F_g$  和惯性力  $F_a$  两部分构成。由于板簧质量分布不均,振动时各部分的加速度不同,通常是中间部分较大,如图 8-2 所示,因此,惯性力的计算需要采用集中等效质量  $m_a$  [218]

$$m_a = 2 \int_0^{\frac{l-l_1}{2}} \frac{2m}{l+l_1} \left( \frac{2x}{l-l_1} \right)^2 dx + 2 \int_{\frac{l-l_1}{2}}^{\frac{l}{2}} \frac{2m}{l+l_1} dx = \frac{2m(l+2l_1)}{3(l+l_1)} \quad (8.9)$$




图 8-2 运动板簧质量及加速度分布图

其中  $m$  为板簧真实质量,  $l$  为板簧长度,  $l_1$  为 U 形螺栓夹紧部位的无效长度;  $a_0$  为板簧中间部位的加速度(等于活塞杆运动加速度)。

经过上述处理后,板簧惯性力的计算  $F_a = m_a a_0$  才比较可靠,而且可以将板簧的静态非线性特征由非线性迟滞恢复力来描述。目前,板簧恢复力模型有双直线模型、物理模型、指数差分模型等,但都不能准确反映板簧的实际特性。文献[218]通过实验证实,不同振幅和静载荷的迟滞恢复力曲线加载/卸载和卸载/加载变化点的梯度  $\partial F / \partial \delta$  基本上不发生变化,从而得出加载/卸载恢复力  $F_H$ 、 $F_L$  的分段描述模型如下:

$$F_H(\delta, R) = F_{CH}(\delta) - C_H(R) e^{-\alpha(\delta+R)} \quad (8.10)$$

$$F_L(\delta, R) = F_{CL}(\delta) - C_L(R) e^{-\beta(R-\delta)} \quad (8.11)$$

其中:  $F_{CH}(\delta) = G_H + K_H \delta$ ;  $F_{CL}(\delta) = G_L + K_L \delta$ ;  $\delta$  为变形位移;  $R$  为振幅;  $G_H, G_L$  反映板簧干摩擦力的大小;  $K_H, K_L$  为加卸载包络线的刚度;  $C_H(R), C_L(R)$  为振幅  $R$  下加卸载开始点在纵坐标轴方向到其包络线的距离。  $\alpha, \beta, G_H, G_L, K_H, K_L$  为特定系数。由(8.10), (8.11)可以看出,板簧的恢复力与其变形  $\delta$ 、振幅  $R$  等有关,是一定区域内的高阶有界非线性分段连续函数。

上述指数模型是在对重载板簧动态往复加载的基础上提出的,虽然可以作为多片板簧迟滞恢复力的统一模型,但并未考虑板簧运动阻尼的影响。对本章研究的轻型轿车板簧,其弹性恢复力迟滞环较小。考虑到运动阻尼的影响及指数模型式可分解成多项式组合,我们用下式来描述板簧动态

$$F = m_a \ddot{\delta} + k_f \dot{\delta} + k_a \delta^2 \dot{\delta} + k_b \delta^3 \quad (8.12)$$

其中  $k_f, k_a, k_b$  为相应项的弹性系数。

结合(8.3)、(8.4)、(8.12)式,并令  $\delta = x_p$ , 则有

$$AP_L = m_1 \ddot{x}_p + B_1 \dot{x}_p + f_0 + F$$

$$\begin{aligned}
&= (m_1 + m_a) \dot{x}_p + (B_1 + k_a x_p^2) \dot{x}_p + k_f x_p + k_b x_p + f_0 \\
&= m_0 \dot{x}_p + B_0(x_p) \dot{x}_p + k_f x_p + k_b x_p^3 + f_0
\end{aligned} \quad (8.13)$$

其中:  $m_0 = m_1 + m_a$ ;  $B_0(x_p) = B_1 + k_a x_p^2$ 。

令:  $x_1 = x_p$ ,  $x_2 = \dot{x}_1$ ,  $x_3 = P_L$ , 则(8.1)、(8.2)和(8.13)式的连立状态方程可描述为

$$\begin{cases} \dot{x}_1 = x_2 \\ m_0 \dot{x}_2 = -(k_f + k_b x_1^2) x_1 - (B_1 + k_a x_1^2) x_2 + A x_3 - f_0 \\ \frac{V_e}{4\beta_e} \dot{x}_3 = -A x_2 - C x_3 + K_{sv} x_v \sqrt{P_s - x_3 \operatorname{sgn}(x_v)} \end{cases} \quad (8.14)$$

显然,对板簧电液伺服系统,位置输出方程和力输出方程与线性弹簧质量系统不同,必须分别加以分析。其中位置输出方程为

$$y_1 = h_1(x) = x_1 \quad (8.15)$$

力输出方程为

$$y_2 = h_2(x) = m_0 \dot{x}_1 + k_f x_1 + k_a x_1^2 \dot{x}_1 + k_b x_1^3 \quad (8.16)$$

由上述分析可见,电液伺服板簧试验系统是本质非线性系统,其状态方程及力控系统的输出方程是状态变量的非线性函数。对这一类非线性系统的稳定性分析是进行控制器设计的基本前提。尤其是对现代计算机控制,为增强系统的可靠性,要求被控系统尽量配置成稳定的系统单元。对于本质非线性系统,传统的线性系统传递函数理论已不再适用,必须采用非线性稳定性理论进行分析和设计。

### 8.3 基于范数空间的稳定性分析

非线性系统理论经过几十年的发展,已形成若干比较成熟的分析方法,如相平面法、描述函数法、Lyapunov 稳定性理论、超稳定性理论以及目前颇受重视的输入输出稳定性理论等。然而,由于非线性系统的多样性和复杂性,非线性系统分析理论远不如线性系统分析理论那么完整和成熟。许多稳定性分析理论都是针对某一类非线性问题提出的,因而不如线性系统理论那样有广泛的适应性。Lyapunov 稳定性理论是人们沿用了很久的分析方法,其中,Lyapunov 第一方法是针对弱非线性系统在平衡点的线性化分析方法,与非线性系统的局部稳定性有关。该方法指出,如果线性化系统是严格稳定的,则非线性系统在平衡点渐进稳定;如果线性化系统不稳定,则非线性系统在平衡点不稳定;但如果线性化系统是临界稳定的,则从中得不到任何结论。Lyapunov 第二方法又称直接稳定性理论,原则上适合一切本质非线性系统,且因其分析方便有效而受到工程界的青睐。但是如何构造 Lyapunov 函数,不仅仅是一个方法,更重要的则是经验和技巧问题。另外,运用 Lyapunov 方法对板簧非线性系统进行稳定性分析时,要涉及求解三阶矩阵问题,工作比较繁琐,且仅能得到平衡点上的稳定条件,却不能给出保证系统稳定的稳定区域<sup>[219]</sup>。

除 Lyapunov 方法外,我们通过研究还发现,Popov 超稳定理论、小增益理论及钝性定理等均难以直接运用于非线性板簧电液伺服系统的分析与设计<sup>[159]</sup>。因此必须找到一种新的更适合一般非线性模型的稳定性分析方法。本节针对一类较普遍的非线性模型,通过理论分析,推导出基于范数空间的稳定性分析方法,可直接用来进行电液伺服板簧试验

系统的稳定性分析。

### 8.3.1 基本理论

设  $R_n$  为  $n$  维实空间, 向量  $x \in R^n, x = (x_1, x_2, \dots, x_n)^T$ , 赋予其向量  $l^2$  范数为  $\|x\| = \sqrt{x_1^2 + x_2^2 + \dots + x_n^2}$ 。设  $D$  是  $R^n$  开凸子集,  $f$  是从  $D$  到  $R^n$  的映射, 若  $f$  满足 Lipschitz 条件, 则定义其最小 Lipschitz 常数为:

$$L(f) = \sup_{x \neq y, x, y \in D} \frac{\|f(x) - f(y)\|}{\|x - y\|} \quad (8.17)$$

易验证  $L(f)$  具有如下性质<sup>[220]</sup>:

(1) 若  $f$  满足 Lipschitz 条件,  $\alpha \in R$ , 则

$$L(\alpha f) = |\alpha| L(f) \quad (8.18)$$

(2) 若  $f, g$  均为满足 Lipschitz 条件的映射, 则

$$L(f + g) \leq L(f) + L(g) \quad (8.19)$$

特别地, 如果  $n$  阶矩阵  $A$  限制在  $D$  上且满足 Lipschitz 条件, 则由于  $D$  是开凸集, 所以有  $L(A) = \|A\|$ ,  $\|A\|$  是  $A$  的矩阵范数。

对上述映射  $f$ , 进一步可定义如下的 Dahlquist 数为<sup>[221]</sup>:

$$M(f) = \lim_{\epsilon \rightarrow 0^+} \frac{L(I + \epsilon f) - 1}{\epsilon} = \lim_{\lambda \rightarrow +\infty} (L(\lambda I + f) - \lambda) \quad (8.20)$$

显然, 若  $f$  为  $n$  阶矩阵  $A$ , 则  $M(f)$  就是  $A$  在  $l^2$  向量范数下的矩阵测度  $\mu(A)$

$$\mu(A) = \lim_{\epsilon \rightarrow 0^+} \frac{\|I + \epsilon A\| - 1}{\epsilon} \quad (8.21)$$

由此可知, Dahlquist 数就是矩阵测度的非线性推广。矩阵测度的正负能刻画线性系统的稳定性, 那么 Dahlquist 数的正负能否刻画相应非线性系统的稳定性呢? 我们给出如下定理。

**定理 8.1** <sup>[221]</sup> 设  $f$  是从  $D$  到  $R^n$  且满足 Lipschitz 条件的映射, 若  $f$  的 Dahlquist 数  $M(f) \leq 0$ , 则非线性系统

$$\dot{x}(t) = f(x(t)), t \geq 0 \quad (8.22)$$

的每个平衡点都是稳定的。若  $M(f) < 0$ , 则系统的平衡点惟一, 且平衡点  $x^*$  是按指数一致渐近稳定的, 即

$$\|x(t) - x^*\| \leq e^{M(f)t} \|x_0 - x^*\| \quad (8.23)$$

其中  $x(t)$  是系统 (8.22) 以  $x_0$  为初值的解。

证明: 因为  $x(t)$  是系统 (8.22) 以  $x_0$  为初值的解,  $x^*$  是平衡点, 则

$$(x(t) - x^*)' = \dot{x}(t) = f(x(t)) - f(x^*), f(x^*) = 0 \quad (8.24)$$

于是,  $\forall \lambda > 0$ , 有

$$\begin{aligned} \lambda(x(t) - x^*) + (x(t) - x^*)' &= \lambda(x(t) - x^*) + f(x(t)) - f(x^*) \\ &= (\lambda I + f)(x(t)) - (\lambda I + f)(x^*) \end{aligned} \quad (8.25)$$

上式两端同乘  $e^{\lambda t}$ , 得

$$(e^{\lambda t}(x(t) - x^*))' = e^{\lambda t}[(\lambda I + f)(x(t)) - (\lambda I + f)(x^*)] \quad (8.26)$$

上式两端同取范数, 得

$$\begin{aligned}
\| (e^{\lambda t}(x(t) - x^*))' \| &\leq \| e^{\lambda t}(x(t) - x^*) \|' \\
&\leq e^{\lambda t} \| (\lambda I + f)(x(t)) - (\lambda I + f)(x^*) \| \\
&\leq e^{\lambda t} L(\lambda I + f) \| x(t) - x^* \|
\end{aligned} \quad (8.27)$$

上式两端同时对  $t$  积分, 有

$$\| e^{\lambda t}(x(t) - x^*) \| \leq \| x_0 - x^* \| + L(\lambda I + f) \int_0^t e^{\lambda \tau} \| x(\tau) - x^* \| d\tau \quad (8.28)$$

由 Gronwell 不等式知,

$$\begin{aligned}
\| e^{\lambda t}(x(t) - x^*) \| &= e^{\lambda t} \| x(t) - x^* \| \leq e^{L(\lambda I + f)t} \| x_0 - x^* \| \\
\Rightarrow \| x(t) - x^* \| &\leq e^{-L(\lambda I + f) \lambda^{-1} t} \| x_0 - x^* \|
\end{aligned} \quad (8.29)$$

令  $\lambda \rightarrow +\infty$ , 即可得到

$$\| x(t) - x^* \| \leq e^{M(f)t} \| x_0 - x^* \| \quad (8.30)$$

所以, 当  $M(f) \leq 0$  时,  $\| x(t) - x^* \| \leq \| x_0 - x^* \|$ , 可见平衡点  $x^*$  是稳定的。

当  $M(f) < 0$  时, 假设系统(8.22)有两个平衡点  $x_1^* \neq x_2^*$ ,  $f(x_1^*) = f(x_2^*) = 0$ , 此时,  $\forall \lambda > 0$ , 由(8.17)式可得

$$\begin{aligned}
L(\lambda I + f) &= \sup_{x \neq y, x, y \in D} \frac{\| (\lambda I + f)(x) - (\lambda I + f)(y) \|}{\| x - y \|} \\
&\geq \frac{\| (\lambda I + f)(x_1^*) - (\lambda I + f)(x_2^*) \|}{\| x_1^* - x_2^* \|} = \lambda
\end{aligned} \quad (8.31)$$

所以,  $M(f) = \lim_{\lambda \rightarrow \infty} (L(\lambda I + f) - \lambda) > 0$ , 这与  $M(f) < 0$  矛盾, 假设不成立。故系统(8.22)平衡点惟一。且由式(8.30)可知, 该平衡点是指数一致渐近稳定的。

定理 8.1 通过对 Dahlquist 数的判断, 就能够得到一般非线性系统的稳定特性。由于实际非线性系统都包含有线性环节, 或者看成是在线性系统上叠加有非线性环节, 因此, 考虑这些特点, 我们设更具一般性的一类非线性系统可描述为:

$$\dot{x} = A_f x(t) + f(x(t)) \quad (8.32)$$

其中  $A_f$  是系统的  $n$  阶线性特征矩阵,  $f(x) = (f_1(x), f_2(x), \dots, f_n(x))^T$  是系统从  $D$  到  $R^n$  的本质非线性连续可微映射。

对系统(8.32)的稳定性, 根据定理 8.1 的结论, 我们给出如下定理。

**定理 8.2** 设  $a$  为矩阵  $A_p = (A_f + A_f^T)/2$  的最大特征值,  $A_p$  为 Hurwitz 矩阵;

$$b_{i,j} = \sup_{x \in D} \left| \frac{\partial f_i(x)}{\partial x_j} \right| < \infty \quad (i, j = 1, 2, \dots, n) \quad (8.33)$$

令  $B = (b_{i,j})_{n \times n}$  是以  $b_{i,j}$  为元素的  $n$  阶矩阵,  $b$  为矩阵  $B_p = (B + B^T)/2$  的最大特征值,  $A_f^T, B^T$  分别为  $A_f, B$  的共轭转置矩阵, 则

(1) 如果  $b + a \leq 0$ , 系统(8.32)的每一个平衡点皆是稳定的。

(2) 如果  $b + a \leq 0$ , 则系统的平衡态惟一, 且平衡点  $x^*$  按指数一致渐近稳定, 即

$$\| x(t) - x^* \| \leq e^{(b+a)t} \| x_0 - x^* \| \quad (8.34)$$

其中  $x(t)$  是系统(8.32)以  $x_0$  为初始状态的解。

证明: 由(8.33)式可知,  $f$  满足 Lipschitz 条件, 且在每点的 Jacobi 矩阵  $D_x(f) \equiv$

$f'(x)$ 满足

$$-B \leq D_x(f) \leq B \quad (8.35)$$

于是,  $\forall \lambda > 0$ ,

$$-(\lambda I + B) \leq \lambda I - B \leq \lambda I + D_x(f) \leq \lambda I + B \quad (8.36)$$

又

$$L(\lambda I + f) = \sup_{x \in b} \|\lambda I + D_x(f)\| \quad (8.37)$$

所以由向量范数的单调性知

$$L(\lambda I + f) \leq \|\lambda I + B\| \quad (8.38)$$

从而  $f$  的 Dahlquist 数满足

$$M(f) \leq \mu(B) \quad (8.39)$$

其中  $\mu(B)$  为  $B$  的矩阵测度, 且为  $B_p$  的最大特征值, 即  $\mu(B) = b$ 。由 (8.20) 式和 (8.39) 式, 可得  $A + f$  的 Dahlquist 数  $M(A + f)$  满足:

$$\begin{aligned} M(A + f) &= \lim_{\lambda \rightarrow +\infty} [L(A + f + \lambda I) - \lambda] \\ &= \lim_{\lambda \rightarrow +\infty} [L(A + \frac{\lambda}{2}I + f + \frac{\lambda}{2}I) - \frac{\lambda}{2} - \frac{\lambda}{2}] \\ &\leq \lim_{\lambda \rightarrow +\infty} [L(A + \frac{\lambda}{2}I) + L(f + \frac{\lambda}{2}I) - \frac{\lambda}{2} - \frac{\lambda}{2}] \\ &\leq \lim_{\lambda \rightarrow +\infty} [L(A + \frac{\lambda}{2}I) - \frac{\lambda}{2}] + \lim_{\lambda \rightarrow +\infty} [L(f + \frac{\lambda}{2}I) - \frac{\lambda}{2}] \\ &= \mu(A) + M(f) \\ &\leq a + b \end{aligned} \quad (8.40)$$

由上式可知, 若定理 8.1 成立, 则定理 8.2 的结论成立。

证毕。

这一定理指出, 由非线性系统的线性特征矩阵和本质非线性映射决定的特征值在一定区域内满足特定的不等式, 就能够得到相应稳定性结论, 同时该区域的大小也就决定了系统的稳定范围。

Lyapunov 稳定性理论主要考查系统在平衡点是否稳定或渐近稳定, 一般需要将系统方程移到平衡点上。上述范数理论是针对一般非线性系统提出的, 主要考查系统的平衡点在多大的区域内是稳定的, 因而无须进行工作点平移。

### 8.3.2 位置闭环系统稳定性分析

现在我们利用上一节的稳定性理论, 对电液位置控制系统进行稳定性分析。

将非线性系统状态方程 (8.14) ~ (8.15) 式写成如下形式:

$$\dot{x} = f(x, u) \quad (8.41)$$

$$y = h(x) \quad (8.42)$$

其中  $y = h(x)$  为输出方程。经推导整理可得系统方程为

$$\dot{x} = \begin{bmatrix} x_2 \\ \frac{1}{m_0} [-(k_f + k_b x_1^2)x_1 - (B_1 + k_a x_1^2)x_2 + Ax_3 - f_0] \\ -\frac{4\beta_e}{V_t}(Ax_2 + C_t x_3) + \frac{4\beta_e}{V_t}K_{xv}x_v \sqrt{(P_s - x_3 \operatorname{sgn}(x_v))} \end{bmatrix} \quad (8.43)$$

$$y = x_1 \quad (8.44)$$

可见在非线性负载下,对电液伺服系统的这种闭环形式,采用线性系统的传递函数理论进行分析是不行的。

为简化分析,设实现电压电流转换功能的伺服放大器为纯比例环节。在电液伺服系统中,伺服阀是动态响应比较快的一个环节,虽然在线性系统中常用一阶惯性传递函数来描述它,但由于本系统只工作在低频段,不失一般性,也将伺服阀作为比例环节看待,即可设从伺服放大器电压输入端到伺服阀阀芯位移  $x_v$  间的增益值为  $K_x$ ,忽略摩擦力  $f_0$  的影响,并设伺服系统的外部输入信号为  $u$ ,则阀芯位移为

$$x_v = K_x(u - x_1) \quad (8.45)$$

进而(8.43)和(8.44)式可写为

$$\dot{x} = \begin{bmatrix} x_2 \\ \frac{1}{m_0} [-(k_f + k_b x_1^2)x_1 - (B_1 + k_a x_1^2)x_2 + Ax_3] \\ -\frac{4\beta_e}{V_t}(K_x x_1 + Ax_2 + C_t x_3) + \frac{4\beta_e}{V_t}K_t u \end{bmatrix} \quad (8.46)$$

$$y = x_1 \quad (8.47)$$

其中:  $K_c = K_{xv}K_x \sqrt{P_s - x_3 \operatorname{sgn}(u - x_1)}$ 。

我们知道,线性系统的稳定性与输入信号无关,而非线性系统的稳定性与输入信号有较大的关系。为分析方便,我们仅考虑输入为零时的稳定性问题。

令  $u = 0$ , 将方程(8.46)式化成(8.32)式的标准形式,有

$$A_f = \begin{bmatrix} 0 & 1 & 0 \\ -\frac{k_f}{m_0} & -\frac{B_1}{m_0} & -\frac{A}{m_0} \\ 0 & -\frac{4\beta_e}{V_t}A & -\frac{4\beta_e}{V_t}C_t \end{bmatrix} \quad (8.48)$$

$$f(x) = \begin{bmatrix} 0 \\ -\frac{1}{m_0}(k_b x_1^3 + k_a x_1^2 x_2) \\ -\frac{4\beta_e}{V_t}K_{xv}x_v x_1 \sqrt{(P_s + x_3 \operatorname{sgn}(x_1))} \end{bmatrix} \quad (8.49)$$

设  $\lambda$  为矩阵  $A_p = (A_f + A_f^T)/2$  的特征值,则可由特征方程  $(\lambda I - A_p) = 0$  得到特征多项式为

$$\lambda^3 + a_2 \lambda^2 + a_1 \lambda + a_0 = 0 \quad (8.50)$$

其中

$$\begin{aligned} a_2 &= \left( \frac{B_1}{m_0} + \frac{4\beta_e}{V_t} C_t \right) \\ a_1 &= \frac{4\beta_e}{V_t m_0} B_1 C_t - \frac{1}{4} \left( 1 - \frac{k_f}{m_0} \right)^2 - \frac{A^2}{4} \left( \frac{1}{m_0} - \frac{4\beta_e}{V_t} \right)^2 \\ a_0 &= -\frac{\beta_e}{V_t} C_t \left( 1 - \frac{k_f}{m_0} \right)^2 \end{aligned}$$

显然(8.50)是不稳定多项式,这是由于线性特征矩阵(8.48)只体现了系统的开环特征信息,因而不是稳定的。

如果忽略伺服阀流量方程的非线性影响,采用近似线性化处理,并令

$$\begin{aligned} \sqrt{P_s + x_3 \operatorname{sgn}(x_1)} &= \sqrt{P_s} \sqrt{1 + x_3 \operatorname{sgn}(x_1)/P_s} \\ &\approx \sqrt{P_s} (1 + x_3 \operatorname{sgn}(x_1)/2P_s) \end{aligned} \quad (8.51)$$

则系统的线性特征矩阵变为

$$A_f = \begin{bmatrix} 0 & 1 & 0 \\ -\frac{k_f}{m_0} & -\frac{B_1}{m_0} & -\frac{A}{m_0} \\ -C_{kp} & -\frac{4\beta_e}{V_t} A & -\frac{4\beta_e}{V_t} C_t \end{bmatrix} \quad (8.52)$$

其中,  $C_{kp} = \frac{4\beta_e}{V_t} K_{xx} X_x \sqrt{P_s}$ 。那么由矩阵的特征方程  $(\lambda I - A_p) = 0$  决定的特征多项式也会产生相应的变化,即

$$\lambda^3 + a_2 \lambda^2 + a_1 \lambda + a_0 = 0 \quad (8.53)$$

其中

$$\begin{aligned} a_2 &= \left( \frac{B_1}{m_0} + \frac{4\beta_e}{V_t} C_t \right); \\ a_1 &= \frac{4\beta_e}{V_t m_0} B_1 C_t - \frac{1}{4} \left( 1 - \frac{k_f}{m_0} \right)^2 - \frac{A^2}{4} \left( \frac{1}{m_0} - \frac{4\beta_e}{V_t} \right)^2 - \frac{C_{kp}^2}{4}; \\ a_0 &= -\frac{\beta_e}{V_t} C_t \left( 1 - \frac{k_f}{m_0} \right)^2 + \frac{C_{kp}}{4} A \left( 1 - \frac{k_f}{m_0} \right) \left( \frac{1}{m_0} - \frac{4\beta_e}{V_t} \right) - \frac{B_1}{4m_0} C_{kp}^2. \end{aligned}$$

式(8.53)为稳定多项式的充要条件是

$$a_1 a_2 > a_0, \quad a_i > 0 \quad (i = 0, 1, 2) \quad (8.54)$$

因为矩阵  $A_p$  实对称,所以当上式成立时,(8.53)的根均为负实数。这样,我们可以找到一个最大的特征值  $\alpha$  为

$$\alpha = \max(\lambda_1, \lambda_2, \lambda_3) \quad (8.55)$$

同样,在不考虑伺服阀流量非线性的情况下,系统状态方程的非线性映射部分(8.49)式相应地变换成

$$f(x) = \begin{bmatrix} 0 \\ -\frac{1}{m_0}(k_b x_1^3 + k_a x_1^2 x_2) \\ -K_{cp} x_1 x_3 \end{bmatrix} \quad (8.56)$$

其中  $K_{cp} = C_{kp}/2P_{sc}$ 。则非线性部分的 Jacobi 矩阵可以求得为

$$\frac{\partial f}{\partial x} = \begin{bmatrix} 0 & 0 & 0 \\ -\frac{1}{m_0}(3k_b x_1^2 + 2k_a x_1 x_2) & -\frac{1}{m_0}k_a x_1^2 & 0 \\ -K_{cp} x_3 & 0 & -K_{cp} x_1 \end{bmatrix} \quad (8.57)$$

对电液伺服系统,状态变量  $x_1, x_2, x_3$  代表系统的位移、速度和压力信号,而且板簧电液伺服系统的工作频率范围为  $0 \sim 20\text{Hz}$ ,最大变形、运动速度和板簧最大静态恢复力都可以直接测定或估计,因此可以得到式(8.57)的矩阵元素最大绝对值构成的矩阵为

$$B = \begin{bmatrix} 0 & 0 & 0 \\ b_1 & b_2 & 0 \\ b_3 & 0 & b_4 \end{bmatrix} \quad (8.58)$$

其中  $b_1, b_2, b_3, b_4$  为矩阵(8.57)对应元素的最大绝对值。 $b_3, b_4$  与系统前向增益直接相关。则矩阵  $B_p$  的特征多项式为

$$\lambda^3 - (b_2 + b_4)\lambda^2 + \left[ b_2 b_4 - \frac{1}{4}(b_3^2 + b_1^2) \right] \lambda + \frac{1}{4}(b_2 b_3^2 + b_4 b_1^2) = 0 \quad (8.59)$$

求解上式可知,(8.59)式为不稳定多项式,有正实根存在,其大小反映了非线性扰动引起的不稳定性。同样,我们可以得到一个最大的特征值  $b$

$$b = \max(\lambda_1, \lambda_2, \lambda_3) \quad (8.60)$$

则由定理 8.2 可知,当  $b + a \leq 0$  时,板簧电液位置伺服系统是稳定的;而当  $b + a < 0$  时,板簧电液位置伺服系统是一致渐近稳定的。

由上述分析可知,在给定系统前向增益下,特征量  $a$  仅由板簧电液位置伺服系统不变的线性特征矩阵  $A_f$  决定;特征量  $b$  的大小受系统可调增益、状态参量的大小及运动范围的制约。因此,根据(8.57)式,并结合系统的稳定性条件,就可以求解系统的稳定性问题。一般均能给出一个稳定的结果,即足够小的  $k_x$  及合适的稳定区域。例如,当系统在工作压力为  $8\text{MPa}$ 、最大负载为  $10\text{kN}$  的条件下,作振幅为  $10\text{mm}$  频率为  $20\text{Hz}$  的正弦运动时,可以验证系统是稳定的<sup>[159]</sup>。

### 8.3.3 力闭环系统稳定性分析

与电液位置伺服板簧试验系统相比,电液力伺服板簧试验系统与前者有着相同的前向通道状态方程,二者的不同之处在于力闭环伺服系统的反馈通道是非线性环节,体现了板簧非线性迟滞恢复力的影响。

设力伺服系统的外部输入信号为  $u$ ,则阀芯位移为

$$x_v = K_x(u - h_0(x)) \quad (8.61)$$

其中  $h_0(x)$  为(8.16)式表示的板簧运动受力。类似地,将上式代入(8.43)式,得系统状态方程为



$$\dot{x} = \begin{bmatrix} x_2 \\ \frac{1}{m_0}[-(k_f + k_b x_1^2)x_1 - (B_1 + k_a x_1^2)x_2 + Ax_3] \\ -\frac{4\beta_e}{V_t}(Ax_2 + C_t x_3) + \frac{4\beta_e}{V_t}K_c(u - h_0(x_1)) \end{bmatrix} \quad (8.62)$$

$$\begin{aligned} y = F &= m_a \dot{x}_2 + k_a x_1^2 x_2 + k_f x_1 + k_b x_1^3 \\ &= \left(1 - \frac{m_a}{m_0}\right)(k_f + k_b x_1^2)x_1 + \left[\left(1 - \frac{m_a}{m_0}\right)k_a x_1^2 - B_1\right]x_2 + \frac{m_a}{m_0}(Ax_3 - f_0) \end{aligned} \quad (8.63)$$

其中,  $K_c = K_{xv}K_x \sqrt{P_s - x_3 \operatorname{sgn}(u - x_1)}$ 。

将方程(8.62)式化成线性特征矩阵方程与本质非线性方程组合形式。令  $u=0$ , 并将伺服阀流量方程按(8.51)式作线性近似处理, 则

$$A_f = \begin{bmatrix} 0 & 1 & 0 \\ -\frac{k_f}{m_0} & -\frac{B_1}{m_0} & -\frac{A}{m_0} \\ -C_{kp}k_f & -\frac{4\beta_e}{V_t}A & -\frac{4\beta_e}{V_t}C_t \end{bmatrix} \quad (8.64)$$

$$f(x) = \begin{bmatrix} 0 \\ \frac{1}{m_0}(k_b x_1^3 + k_a x_1^2 x_2) \\ -C_{kp}g(x) \end{bmatrix} \quad (8.65)$$

其中:

$$C_{kp} = \frac{4\beta_e}{V_t}K_{xv}K_v \sqrt{P_s}$$

$$\begin{aligned} g(x) &= (m_a \dot{x}_2 + k_a x_1^2 x_2 + k_b x_1^3) \left(1 + \frac{x_3}{2P_s}\right) + \frac{x_1 x_3}{2P_s} k_f \\ &= \left\{ \left[ \left(1 - \frac{m_a}{m_0}\right)k_b x_1^2 - \frac{m_a}{m_0}k_f \right]x_1 + \left[ \left(1 - \frac{m_a}{m_0}\right)k_a x_1^2 - B_1 \right]x_2 + \frac{m_a}{m_0}Ax_3 \right\} \\ &\quad \left(1 + \frac{x_3}{2P_s}\right) + \frac{x_1 x_3}{2P_s} k_f \end{aligned}$$

可见力闭环系统的线性特征矩阵与位置闭环系统基本一致, 这是由于力闭环系统与位置闭环系统的前向通道完全一样, 而闭环通道主增益不同所致。因此由矩阵  $A_p = (A_f + A_f^T)/2$  的特征方程  $(\lambda I - A_p) = 0$  决定的特征多项式与位置系统略有不同, 为

$$\lambda^3 + a_2 \lambda^2 + a_1 \lambda + a_0 = 0 \quad (8.66)$$

其中

$$\begin{aligned} a_2 &= \left( \frac{B_1}{m_0} + \frac{4\beta_e}{V_t}C_t \right) \\ a_1 &= \frac{4\beta_e}{V_t m_0} B_1 C_t - \frac{1}{4} \left( 1 - \frac{k_f}{m_0} \right)^2 - \frac{A^2}{4} \left( \frac{1}{m_0} - \frac{4\beta_e}{V_t} \right)^2 - \frac{C_{kp}^2}{4} k_f^2 \end{aligned}$$

$$a_0 = -\frac{\beta_e}{V_t} C_t \left(1 - \frac{k_f}{m_0}\right)^2 + \frac{C_{kp}}{4} k_f A \left(1 - \frac{k_f}{m_0}\right) \left(\frac{1}{m_0} - \frac{4\beta_e}{V_t}\right) - \frac{B_1 k_f^2}{4m_0} C_{kp}^2$$

(8.66)式为稳定多项式的充要条件是

$$a_1 a_2 > a_0, \quad a_i > 0 \quad (i = 0, 1, 2) \quad (8.67)$$

与(8.53)式相比,由于 $k_f$ 的作用,上述多项式的稳定条件可能被破坏,因此有必要减小前向通道增益 $k_x$ 。这与实际系统中,力闭环控制与位置闭环控制不能共用一个伺服放大器增益是一致的。同样,我们可以得到一个最大的特征值 $a$ 为

$$a = \max(\lambda_1, \lambda_2, \lambda_3) \quad (8.68)$$

下面来考查本质非线性方程(8.65)式,其Jacobi矩阵为

$$\frac{\partial f}{\partial x} = \begin{bmatrix} 0 & 0 & 0 \\ \frac{-1}{m_0}(3k_b x_1^2 + 2k_a x_1 x_2) & \frac{-1}{m_0} k_a x_1^2 & 0 \\ g_1(x) & g_2(x) & g_3(x) \end{bmatrix} \quad (8.69)$$

其中:

$$g_1(x) = \left[ \left(1 - \frac{m_a}{m_0}\right) (k_f + 3k_b x_1^2 + 2k_a x_1 x_2) - \frac{m_a}{m_0} k_f \right] \left(1 + \frac{x_3}{2P_s}\right) C_{kp} + \frac{x_3}{2P_s} k_f C_{kp}$$

$$g_2(x) = \left[ \left(1 - \frac{m_a}{m_0}\right) k_a x_1^2 - B_1 \right] \left(1 + \frac{x_3}{2P_s}\right) C_{kp}$$

$$g_3(x) = \left[ \frac{m_a}{m_0} A \left(1 + \frac{x_3}{P_s}\right) + \frac{x_1}{2P_s} k_f \right] C_{kp}$$

由上式可见,估计力伺服系统的 $|\partial f / \partial x|$ 远比位置伺服系统困难和复杂,但仍然是数值可解的。与位置系统类似,我们可以构造特征矩阵 $B_p$ ,二者形式完全相同,仅数值不一样。因此也可以求出最大特征值 $b$ 。当条件 $b + a \leq 0$ 满足时,系统是稳定的,同时可以得到相应的稳定区域。同样,在8.3.2节假设的工作条件下,我们可以检验,力闭环控制系统是稳定的。

## 8.4 电液伺服板簧试验系统特性研究

电液伺服板簧试验系统是一个典型的非线性系统,主要反映在板簧弹性恢复力与变形之间呈非线性关系。由于弹性恢复力的存在,使得位置伺服系统和力伺服系统的前馈通道不再是简单的线性系统。因此与线性弹簧质量系统不同,板簧伺服系统的稳态性与输入幅度和预加载荷的大小(初始工作点)有关,输出信号也有较大的变化。

另外,不论是力反馈控制系统,还是位置控制系统,采用纯比例环节的伺服放大器时,系统均是零阶系统,且阶跃输入稳态有差。为此,我们采用惯性积分补偿和电流微分负反馈伺服放大器,通过硬件电路实现串联校正,以便改善系统的静、动态特性,为后续神经网络控制策略的应用提供较好的硬件基础。

### 8.4.1 静态特性试验

静态特性试验的目的是求出板簧弹性恢复力与变形之间的关系曲线。试验装置如图




图 8-3 板簧试验装置

8-3 所示,试验对象为轻型轿车板簧,加载方式采用力闭环控制和位置闭环控制均可。

试验中发现,板簧电液伺服系统的非线性主要表现在:(1)加载幅度不同,曲线不同;(2)相同幅值下,不同次的试验曲线不完全一致;(3)加载和卸载曲线略有不同,表示板簧有一定的回环特性。

由于本节研究的是轻型轿车板簧,其非线性回环特性不大,为简化分析,忽略其影响;另外,静态试验不考虑阻尼的影响,因此我们假设板簧的静态恢复力曲线方程为

$$F_0(\delta) = k_1\delta + k_2\delta^3 \quad (8.70)$$

表 8-1 给出了变形在  $\delta \in (0, 45)\text{mm}$  的情况下,板簧静态加载试验数据。由于板簧电液伺服系统表现为较强的非线性特征,每条静态试验曲线不尽相同,表中的试验曲线是经多次试验取平均得到的。

表 8-1 板簧静态试验数据

序号	1	2	3	4	5	6	7	8	9	10	11
$\delta(\text{mm})$	0.22	10.53	15.12	18.96	22.24	24.23	27.21	31.48	35.22	38.52	42.51
$F_0(\text{N})$	0.0	52.2	118.3	181.5	213.2	243.1	300.8	417.6	505.8	562.5	671.2

由表中数据得到的拟合曲线如图 8-4 所示。拟合方程为

$$F_0(\delta) = 7.5187\delta + 0.0049\delta^3 \quad (8.71)$$

#### 8.4.2 位置控制特性试验

试验条件如下:系统压力为  $8\text{MPa}$ ,油温为  $35 \pm 5^\circ\text{C}$ ,输入信号为  $0.5\text{V}/10\text{mm}$ 。图 8-5 是  $5\text{mm}$  阶跃响应曲线,可见有  $0.2\text{mm}$  左右的稳态误差,稳态纹波是由于伺服阀颤振信号过大和系统噪声引起的。图中 Pre-force 代表预加载力。




图 8-4 板簧静态试验曲线




图 8-5 位置伺服系统阶跃响应

图 8-6 是幅值为 5mm 频率为 5Hz 正弦波响应曲线,此时,板簧的预加载荷为 660.6N。可见系统存在较大的相位误差和波形失真。经多次试验发现,整个闭环系统的




图 8-6 位置伺服系统正弦波响应曲线

动态频响仅有 9.5Hz,而且 5Hz 以上波形失真较大;对低频正弦信号的响应较好,但仍有一定的相位误差。为节省篇幅,此处未予列出。

#### 8.4.3 力控制特性试验

板簧恢复力与油缸位移呈非线性关系,因此在动态加载时,力的波形与位移波形不一致。研究还表明<sup>[118]</sup>,在不同的幅值和频率下,力伺服系统响应也不一样。经试验发现,板簧力伺服系统的动态频响仅有 2.8Hz,而且 2Hz 以上波形失真较大。

图 8-7 是力控制系统 300N 阶跃响应曲线,可见有 10% 的稳态误差。




图 8-7 力控制系统阶跃响应

图 8-8 是幅值为 300N 频率为 2Hz 的正弦响应曲线。由系统的 Bode 图可知,此时存在的主要误差是相位误差,曲线不光滑是因为板簧非线性反馈力作用的结果。




图 8-8 力控制系统正弦输入响应

通过以上试验还发现,不论是力反馈系统还是位置反馈系统,在相同的工作点上(以

板簧变形量为准),不同次试验伺服阀的静态电流不一致,主要是由不同试验时的系统摩擦力及板簧恢复力不一样造成的。正弦响应试验中,力控系统及位控系统的输出波形都有不同程度的失真,且以力控系统输出波形的失真为大,这与力控系统反馈通道的非线性属性息息相关。阶跃试验中,系统的输出幅度与其输入不成线性关系,而且稳态有差。这是电液伺服板簧试验系统非线性特征的又一表现。

## 8.5 神经网络自适应控制试验研究

通过分析和试验研究发现,电液伺服板簧试验系统具有较强的非线性,采用传统的PID控制策略难以获得较好的控制效果。本节针对这一特点,采用神经网络控制方法,分别对力闭环系统和位置闭环系统进行控制试验。以期提高板簧试验系统的控制品质。

### 8.5.1 位置伺服系统的神经网络控制

电液位置伺服板簧试验系统的特点是,在系统前馈环节上,存在板簧非线性内力反馈作用,该力不仅造成了对系统较强的干扰,而且构成了零型稳态有差系统。给系统控制带来了不利影响。为克服这一影响,本节采用基于神经网络辨识的在线迭代学习控制和模型参考神经网络直接自适应控制两种控制策略对系统实施控制。

#### 1. 基于神经网络辨识的在线迭代学习控制试验

基于神经网络辨识的在线迭代学习控制器及算法设计如第七章所述,辨识网络采用复合输入DRNN,结构为 $(1+6) \times 6 \times 1$ ,初始权值选取小随机值;参考模型可由电路实现也可由数字实现。为简单起见,线性估计模型和参考模型采用相同的结构,且均为数字实现的一阶系统。考虑到模型的辨识精度和控制量的迭代精度,单步辨识次数及迭代循环次数取得较大,因而采样时间定为25ms。试验条件为:系统压力为8MPa,油温为 $35 \pm 5^\circ\text{C}$ 。

图8-9给出5mm阶跃控制结果。由图可知,控制进入稳态大约需要0.18秒。与图8-5相比,稳态误差由0.2mm降为0.1mm。稳态纹波是由于伺服阀颤振信号过大、控制




图8-9 位置伺服系统阶跃控制结果

器频繁作用造成的。图 8-10 和图 8-11 分别是 1Hz 及 2Hz 正弦波的控制结果。由图可见,控制效果虽然不理想,但从波形跟踪的角度看,神经网络控制器的作用是明显的。造成控制精度不高的原因主要有两点,一是采样点数目不足,二是存在较大的系统噪声,使神经网络辨识较难收敛或精度欠佳。由此可见,对神经网络辨识结果的较强依赖是这种控制方法的优点,也是其致命的缺点。




图 8-10 1Hz 正弦波控制结果




图 8-11 2Hz 正弦波控制结果

## 2. 模型参考神经网络直接自适应控制试验

模型参考神经网络直接自适应控制采用混合神经网络控制策略,其中线性网络结构为  $6 \times 1$ ; BP 网络结构为  $6 \times 6 \times 1$ ; 输入向量均由参考模型的输入输出、被控对象的输入、被控量位移输出信号及附属力输出信号和控制误差组成,网络初始权值取较小的随机数。这种方式能够保证板簧电液力伺服控制系统和板簧电液位置伺服控制系统有相同的控制器结构,差别仅在被控量和控制误差不同。考虑到实时控制时信号噪声较大,学习算法采用广义 PI 算法形式,没有微分项。采样时间定为 10ms。其他条件同上。




图 8-12 位置伺服系统阶跃控制结果





图 8-13 神经网络直接自适应控制正弦响应



图 8-12 给出了 5mm 阶跃控制结果。可以看出,阶跃响应稳态无差,其中 5% 左右的纹波主要是由电路噪声及伺服阀颤振频率引起的,控制效果优于图 8-5 的控制效果。

图 8-13 是对频率为 0.5Hz 幅值为 3.5mm 正弦波的跟踪控制曲线。在较小的随机初始权值下,可以观察到控制稳定收敛的过程,2 分钟后控制误差可达 5% 以内,如图 8-13(b)所示。

图 8-14 是对幅值为 5mm 频率为 5Hz 正弦波的跟踪控制曲线,稳态控制误差约为 20%,但是与图 8-6 相比,波形失真度及控制误差已有十分明显的改善。




图 8-14 神经网络直接自适应控制正弦响应

通过研究发现,为保证对周期信号的控制精度,每个周期内的采样点数不能太少,约在 40 个左右比较合适。但由于受计算时间的影响,采样点数又不能太多,因而对较高频率信号的控制效果较差。图 8-14 的跟踪结果也说明了这一点。

### 8.5.2 力伺服系统的神经网络控制

与位置系统不同,力伺服系统不仅前向通道存在非线性内力反馈,而且输出力反馈环节也是非线性的。对系统造成的不利影响更为严重。本节仍采用基于神经网络辨识的在线迭代学习控制和模型参考神经网络直接自适应控制两种控制策略对系统实施控制。

#### 1. 基于神经网络辨识的在线迭代学习控制试验

基于神经网络辨识的在线迭代学习控制器及控制算法设计与 8.5.1 节相同,采样时间定为 25ms。图 8-15 是 300N 阶跃力加载的响应结果,其中 Pre. force 代表预加载力。可以看出,神经网络经过若干次学习后,能够达到稳态无差的理想控制效果。明显优于图 8-7 的控制效果。改变加载力幅值,控制效果基本不变。

图 8-16 是神经网络辨识控制 2 分钟后,幅值为 300N 频率为 0.5Hz 的正弦波力加载响应情况。其中神经网络初始权值由若干次在线学习产生的。可以看出,经过 2 分钟的在线辨识控制,稳态误差达到 5% 以内,控制效果相当理想。提高输入信号频率后,控

制效果变差,但适当调节在线学习次数和控制参数,控制效果相对于图 8-8 仍有明显改善。




图 8-15 阶跃力控制响应




图 8-16 正弦力控制响应





图 8-17 混合神经网络 400N 阶跃力控制


## 2. 模型参考神经网络直接自适应控制试验

模型参考神经网络直接自适应控制策略及混合神经网络控制器结构设计与 8.5.1 节完全相同,仅控制参数不同。这时控制量为力,神经网络控制器的输入向量应包含力的输出跟踪误差。采样时间定为 10ms。

图 8-17 是 400N 阶跃控力控制曲线,此时预加载力为 476.8N,稳态控制误差为零,控制效果明显优于图 8-7 稳态控制有差的结果。



(a) 起始控制时



(b) 1分钟后

图 8-18 混合神经网络动态力加载控制结果

图 8-18 是幅值为 300N 频率为 2Hz 的正弦控制曲线,预加载力为 666N。可以看出,由于系统的非线性比较严重,在 2Hz 正弦输入时相位滞后较大;加之控制能量有限,仅为 30mA/10V,为防止计算饱和而造成控制发散,实时控制参数都选择较小,所以控制收敛较慢。但经过有限时间学习后,控制结果相当理想,稳态收敛误差达到 5%,如图 8-18(b)所示。控制效果与图 8-8 相比有明显改善。

另外,实验中我们发现,对位置伺服控制系统,神经网络控制策略比较容易实施,网络结构及学习参数可在较大的范围内进行选择,都能得到稳定的控制结果。但对力控制系统,由于反馈通道非线性的影响,控制结果相对容易发散,控制器参数的选择范围较小。

## 8.6 本章小结

本章首先从电液伺服系统的角度,对板簧的非线性特性进行了详细的分析,提出了板簧等效运动质量的概念。其次,为研究电液伺服板簧试验系统这一类典型非线性系统的稳定性,我们将现代非线性系统理论的最新研究成果运用于电液伺服板簧试验系统的稳定性分析中,提出了线性特征矩阵和本质非线性映射的概念,推导出一种判断非线性系统稳定性的新方法,并由此得到了位置闭环系统和力闭环系统的稳定性条件。我们认为,对于实际的非线性系统,得到关于系统稳定性的数值解更具有工程意义。然后,通过静、动态试验,进行了电液伺服板簧试验系统的特性研究,结果表明它是一个本质非线性系统,位置闭环系统特性以及力闭环系统特性均与线性系统完全不同。因此,对板簧试验系统,采用非线性设计方法和控制策略是必要的。

最后,分别利用本书第五章和第七章提出的基于神经网络辨识的在线迭代学习控制策略及模型参考神经网络直接自适应控制策略,对板簧试验系统进行了控制试验研究。结果表明,神经网络控制策略对处理电液伺服板簧试验系统中的非线性问题是有效的。且从一般意义上讲,对位置控制系统,神经网络控制策略的实现相对方便,控制效果也优于力伺服系统。

## 第九章 不对称缸电液伺服系统神经网络 补偿非线性控制

### 9.1 引言

电液伺服系统是本质的非线性系统已为人们所共识,其非线性的来源有二:一是负载非线性,如第八章的板簧非线性负载;其次是驱动缸系统本身,如伺服阀开口不对称、流量方程非线性、系统耦合、库仑摩擦及油温变化对油液粘度的影响等。用传统的工作点线性化方法设计控制器时,控制效果依赖于线性化精度和所在的工作点。若工作点发生变化,就必须重新设计控制器参数,甚至调整控制器的结构。用反馈线性化技术进行控制器的设计,则可以使控制器的工作区域得到较大程度的扩展。文献[129]研究了对称缸惯性质量负载系统的反馈线性化设计问题。然而我们发现,对于纯惯性质量负载的对称缸系统,可用数学方程描述的非线性仅为其流量方程。在工作点附近的小范围内进行线性化处理并采用传统的PID控制方式,实际效果可以很好,足以满足一般的使用要求。当负载较大或工作区域变化较大时,伺服阀阀口流量方程的非线性才略有体现。因此一般地,对位置伺服系统而言,伺服阀总工作在零开口附近,单纯考虑伺服阀流量非线性影响的意义并不大。

与对称缸系统不同的是,不对称缸系统除了伺服阀阀口流量呈非线性外,油缸两腔面积不对称的非线性对系统的影响很大,这一点在振动控制问题中尤为突出。不对称缸电液伺服系统是指液压系统中的油缸为单出杆形式,其特点是占用空间小、制造简单、成本低廉,因此在液压动力机构中被广泛采用。由于活塞两腔面积不等,流量是非线性的,所以给系统控制带来了困难。过去,由于采用常规线性PID控制难以达到较高的控制精度,因而给人们造成一种误解,即这种不对称缸系统只能用于低精度的场合。然而,事实上,不对称缸系统因其占用空间小,可提供较大的加速度等原因,在大型挖掘机、多自由度振动台、航空模拟器、大型多关节机器人等<sup>[130]</sup>方面应用非常广泛。因此,随着系统设计要求的提高,研究不对称缸系统非线性控制策略的迫切性显得日益突出。

在本书的前面章节中,我们讨论了多种基于神经网络的控制方法。它们基本上都属于一种“无模型”的控制方法,即将被控对象完全作为“黑箱”来处理。这种方法的优点是结构简单,理论上可适用于一切连续的非线性系统。但要求系统自身是BIBO的,且由于未有效利用系统可能的已知信息,控制效果是否最为理想尚难定论。反过来说,如果能够建立一个非线性系统比较精确、甚至是完全精确的数学模型,而在进行控制器的设计时却完全不考虑这些知识,显然有欠妥之处。

反馈控制是自动控制理论的基石。对于线性系统,经过几十年的发展,已建立起了一套完整成熟的理论体系,如LQR、ITAE最优控制、零极点配置等;非线性系统的情况比较复杂,包罗万象,迄今还没有统一的设计理论和稳定分析方法。神经网络给非线性控制带来了新的曙光。但由于古典控制理论对严格数学推导的依赖性一直影响着人们进行神经

网络控制器的设计,因而引起了对单纯神经网络控制研究的争议。而另一方面,由于受到非线性系统理论和神经网络技术发展的制约,要具备类似于线性系统那样严格的数学推导,形成一种完整的神经网络控制设计体系尚需假以时日。在这种情况下,将非线性系统在工作点“近似”线性化处理,然后作为线性系统来对待,不失为一种工程实用方法。然而,“近似”处理又造成系统的工作区域很窄,且精度有限,给实际应用带来了许多限制。为此人们进而谋求“精确线性化(Exact-linearization)”技术。顾名思义,“精确线性化”就是运用数学方法如状态反馈线性化和输入输出反馈线性化,对模型精确已知的非线性系统进行全局线性化处理。这样经过反馈线性化处理后的非线性系统就可以完全视为线性系统,然后即可按照线性系统的设计方法来进行系统设计。目前,微分几何、微分代数的发展对“精确线性化技术”的实现提供了实用的数学工具。

微分几何方法主要针对仿射类非线性系统,且要求系统模型精确已知。当模型参数有差,或有模外动态存在时,就必须考虑控制系统的鲁棒性。如何进行模型失配下的自适应设计和鲁棒性设计,是关系到反馈线性化方法能否真正走向实际应用的关键。本章针对不对称缸电液伺服系统控制的需要,采用反馈线性化技术进行分析和设计,并利用神经网络控制技术实现对系统中不确定因素的在线补偿控制。

## 9.2 基本理论<sup>[3~7]</sup>

为便于理解,我们首先对微分几何反馈线性化方法中的基本概念和数学工具进行必要的阐述。为避免概念上和符号上的复杂性,本节直接以仿射非线性系统为研究对象,来讨论这些知识。

**定义 9.1** 设矢量函数  $f(x)$  是  $R^n$  上的一个矢量场,如果具备要求的任意阶连续偏导数存在,则该函数为光滑的。

**定义 9.2** 令  $h: R^n \rightarrow R$  为一个光滑的标量函数,  $f: R^n \rightarrow R^n$  为  $R^n$  上的一个光滑的矢量场,则  $h$  对  $f$  的李导数是一个定义为  $L_f h = \nabla h f = \frac{\partial h}{\partial x} \cdot f$  的标量函数。

可见,李导数其实就是  $h$  沿矢量  $f$  方向的方向导数。

多重李导数可递归定义为

$$\begin{aligned} L_f^0 h &= h \\ L_f^i h &= L_f(L_f^{i-1} h) = \nabla(L_f^{i-1} h) f \quad (i = 1, 2, 3, \dots) \end{aligned}$$

考查如下的单输出动态系统,不难看出李导数与动态系统之间的联系。

$$\begin{cases} \dot{x} = f(x) \\ y = h(x) \end{cases}$$

系统输出对时间的导数与李导数的关系为

$$\begin{aligned} \dot{y} &= \frac{\partial h}{\partial x} \dot{x} = L_f h \\ \dot{y} &= \frac{\partial (L_f h)}{\partial x} \dot{x} = L_f^2 h \end{aligned}$$

**定义 9.3** 令  $f$  与  $g$  为  $R^n$  上的两个矢量场,  $f$  与  $g$  的李括号是第三个矢量场,定义为:

$$[f, g] = \nabla gf - \nabla fg = \text{ad}_f g$$

同样,多重李括号可以递归定义为:

$$\begin{aligned} \text{ad}_f^0 g &= g \\ \text{ad}_f^j g &= [f, \text{ad}_f^{j-1} g] \quad (j = 1, 2, \dots) \end{aligned}$$

李括号具备下列性质:

(1) 双线性

$$\begin{aligned} [a_1 f_1 + a_2 f_2, g] &= a_1 [f_1, g] + a_2 [f_2, g] \\ [f, a_1 g_1 + a_2 g_2] &= a_1 [f, g_1] + a_2 [f, g_2] \end{aligned}$$

其中:  $f_1, f_2, f, g, g_1, g_2$  均为光滑的矢量场;  $a_1, a_2$  为常标量。

(2) 斜交换性

$$[f, g] = -[g, f]$$

(3) 雅可比 Jacobi 恒等式

$$L_{\text{ad}_f} g = L_f L_g h - L_g L_f h$$

将熟知的坐标变换的概念进行推广,可以得到微分同胚的新概念。

**定义 9.4** 定义在区域  $\Omega$  上的函数  $\phi: R^n \rightarrow R^n$ , 如果它是光滑的, 其逆  $\phi^{-1}$  存在且光滑, 则称之为该函数的一个微分同胚。

构造全局微分同胚即  $\Omega$  是整个空间  $R^n$  相当困难, 常常只能寻找局部微分同胚, 即仅在一个给定点的邻域内定义的变换。

**定理 9.1** 令  $\phi(x)$  是在  $R^n$  中的区域  $\Omega$  内定义的一个光滑函数, 如果 Jacobi 矩阵  $\nabla \phi$  在  $\Omega$  内一点  $x = x_0$  处非奇异, 则  $\phi(x)$  在  $\Omega$  的一个子区域内为一个局部的微分同胚。

微分同胚可用来将一个非线性系统变换成另一个用新的状态表示的非线性系统。

在处理  $n$  阶非线性系统反馈线性化问题时, 我们必须定性地知道这组偏微分方程是否可解, 以及在什么条件下可解。Frobenius 定理<sup>[7]</sup>给出了一类特殊偏微分方程可解性的充要条件。在叙述 Frobenius 定理之前, 先给出如下定义:

**定义 9.5**  $R^n$  上的一组线性无关的矢量场  $\{f_1, f_2, \dots, f_m\}$  是完全可积的, 当且仅当存在  $n - m$  个标量函数  $h_1(x), h_2(x), \dots, h_{n-m}(x)$  满足一组偏微分方程

$$\nabla h_i f_j = 0$$

其中:  $1 \leq i \leq n - m, 1 \leq j \leq m$ ; 而梯度  $\nabla h_i$  是线性无关的。

**定义 9.6** 线性无关的矢量场集合  $\{f_1, f_2, \dots, f_m\}$  是对合的, 当且仅当存在标量函数  $a_{ijk}: R^n \rightarrow R$  使

$$[f_i, f_j](x) = \sum_{k=1}^m a_{ijk}(x) f_k(x) \quad \forall i, j$$

对合的意思就是如果从矢量场集合  $\{f_1, f_2, \dots, f_m\}$  中任取一对来组成李括号, 则得到的矢量场可以表示为原先集合中的矢量场的线性组合。

**定理 9.2** (Frobenius 定理) 令  $f_1, f_2, \dots, f_m$  为一组线性无关的矢量场, 当且仅当这个集合为对合时, 它是完全可积的。

另外, 对线性系统, 我们有系统阶数的概念; 对非线性系统, 类似地有关系度的重要概念。

定义 9.7 设非线性系统

$$\begin{cases} \dot{x} = f(x) + g(x)u \\ y = h(x) \end{cases} \quad (9.1)$$

其中:  $x \in R^n, y \in R, f(x), g(x)$  是向量场。如果对于所有在  $x^0$  邻域内的  $x$ , 有

$$(1) L_g L_f^k(x) = 0 \quad k < r-1$$

$$(2) L_g L_f^{r-1} h(x) \neq 0$$

则认为系统(9.1)在  $x^0$  的邻域中的关系度为  $r$ 。

## 9.3 非线性系统反馈线性化设计

### 9.3.1 一般方法

对(9.1)式所示仿射非线性系统, 如果系统的阶数为  $n$ , 关系度为  $r$ , 则可以经过如下微分同胚变换化为线性系统。

(1) 当  $r = n$  时, 选择

$$z = \phi(x) \cdot \begin{bmatrix} h(x) \\ L_f h(x) \\ \vdots \\ L_f^{n-1} h(x) \end{bmatrix}$$

则有

$$\begin{cases} \dot{z}_1 = z_2 \\ \dot{z}_2 = z_3 \\ \vdots \\ \dot{z}_n = a(x) + b(x)u = L_f^n h(x) + L_g L_f^{n-1} h(x)u \end{cases} \quad (9.2)$$

可见在上式中, 前  $n-1$  个方程都被线性化了, 且不显含控制量, 只有最后一个显含控制量的方程是非线性的。

(2) 当  $r < n$  时, 取

$$\begin{cases} z_1 = \phi_1(x) = h(x) \\ z_2 = \phi_2(x) = L_f h(x) \\ \vdots \\ z_r = \phi_r(x) = L_f^{r-1} h(x) \end{cases}$$

对其余  $n-r$  个坐标, 取

$$\begin{cases} z_{r+1} = \phi_{r+1}(x) \\ \vdots \\ z_n = \phi_n(x) \end{cases}$$

且满足

$$L_g \phi_i(x) = 0 \quad (r+1 \leq i \leq n) \quad (9.3)$$

则有



$$\begin{cases} \dot{z}_i = L_f^i h(x) = z_{i+1} & (i < r) \\ \dot{z}_r = L_f^r h(x) + L_g L_f^{r-1} h(x) u|_{x=\phi^{-1}(z)} = a(z) + b(z)u \\ \dot{z}_{r+j} = \frac{\partial \phi_{r+j}}{\partial x} \dot{x} = L_f \phi_{r+j}(\phi^{-1}(z)) + L_g \phi_{r+j}(\phi^{-1}(z)u) & (r+j \leq n) \end{cases}$$

根据条件(9.3)式,有

$$\dot{z}_{r+j} = L_f \phi_{r+j}(\phi^{-1}(z)) \quad (r+j \leq n)$$

可见,对非线性系统(9.1)式,当  $r < n$  时,进行分段线性变换,且  $\phi(x)$  在  $x^0$  处的 Jacobi 矩阵  $J_\phi = \partial \phi(x)/\partial x|_{x^0}$  非奇异,则有如下标准型:

$$\begin{cases} \dot{z}_1 = z_2 \\ \vdots \\ \dot{z}_r = a(z) + b(z)u \end{cases} \quad \begin{cases} \dot{z}_{r+1} = q_{r+1}(z) \\ \vdots \\ \dot{z}_n = q_n(z) \end{cases} \quad (9.4)$$

由上述分析可见,对非线性系统线性化的步骤可归纳如下:

- ①判明关系度。
- ②选择变换  $z = \phi(x)$ 。
- ③检验  $\phi(x)$  是否微分同胚,即其 Jacobi 矩阵是否非奇异。
- ④求逆变换  $x = \phi^{-1}(z)$ 。
- ⑤求出新的线性系统标准型。

上述求解过程的困难是,当  $r < n$  时,须求解偏微分方程,否则得不到完全的线性化标准型。

对于 SISO 系统,无论是  $r < n$  或  $r = n$ ,当求取系统的线性化标准型后,都可以从线性化标准型中(完全或不完全的)直接求出控制量的表达式,进而求出对于期望控制目标或控制状态的控制量。如令

$$\dot{z}_r = a(z) + b(z)u = v \quad (9.5)$$

其中  $v$  为新的控制量。则系统的线性化模型变为:

$$\dot{z} = Az + Bv$$

其中:

$$A = \begin{bmatrix} 0 & 1 & & 0 \\ 0 & 0 & 1 & 0 \\ & & & \ddots \\ & & & 1 & 0 \\ & & & & 0 \end{bmatrix}_{(r-1) \times (r-1)} \quad B = [0, 0, \dots, 1]^T$$

对该线性化模型,运用线性系统控制原理,如极点配置、LQR 等方法即可进行状态反馈设计,然后由方程(9.5)即可求出实际系统的控制量为:

$$u = \frac{v - a(z)}{b(z)} = \frac{v - L_f^r h(k)}{L_g L_f^{r-1} h} \quad (9.6)$$

对于 MIMO 系统,上述运算就不那么简单了。读者可参阅文献[6,7]。

非线性系统反馈线性化设计有输入/状态反馈线性化方法和输入/输出反馈线性化法。输入/状态反馈线性化法须进行状态转换,因而对 SISO 控制系统而言,常采用输入/输出反馈线性化法。即直接对输出方程求导,直到在输出方程中有显含控制量出现。

需要指出的是,当非线性系统的  $r < n$  时,将会产生零动态系统稳定性问题。关于这一点,本章不再作详细讨论,读者可参阅相关文献[7]。为后面设计需要,这里仅给出零动态系统的定义。

**定义 9.8** 当系统(9.4)式前  $r$  个方程为零时,后面的  $n - r$  个方程就描述了原始非线性系统(9.1)式的零动态子系统,即

$$\begin{cases} \dot{\mu} = 0 \\ \dot{\psi} = \omega(\mu, \psi) \end{cases} (\mu = 0) \quad (9.7)$$

其中  $\mu = (z_1, z_2, \dots, z_r)^T$ ,  $\psi = (z_{r+1}, z_{r+2}, \dots, z_n)^T$ 。

### 9.3.2 非线性系统反馈线性化控制

一般而言,非线性系统的控制包括稳定调节控制和伺服跟踪控制两大类。下面的定义可将这两个问题统一起来。

**定义 9.9** 渐近稳定问题是指给定一个非线性动态系统:

$$\begin{cases} \dot{x} = f(x, u, t) \\ y = h(x) \end{cases} \quad (9.8)$$

以及期望的输出轨迹  $y_d$ , 求输入控制律  $u$ , 使得从区域  $\Omega$  中的任何动态开始, 系统的跟踪误差满足

$$\lim_{t \rightarrow \infty} y(t) - y_d(t) = 0 \quad (9.9)$$

而整个状态保持有界。若有适当的初始状态能使闭环系统的跟踪误差恒为零, 即

$$y(t) = y_d(t) \quad \forall t \geq 0 \quad (9.10)$$

则称系统能实现理想跟踪。若系统能渐近地到达上述理想跟踪, 则称之为渐近跟踪。这里假定期望轨迹及其足够高阶的导数(通常等于系统的阶数)都是连续有界的, 且可以直接加以利用。

从上面的定义可见, 稳定问题可以化为一个调节器的设计问题, 或为一个常值的跟踪控制问题; 而求解轨迹跟踪要困难得多, 不仅要保持整个状态的稳定, 还要驱使系统的输出逼近期望的输出轨迹。不过理论上, 跟踪设计与稳定设计常常是互相联系的。例如, 对跟踪问题  $\dot{y} + f(\dot{y}, y, u) = 0$ , 使  $e(t) = y(t) - y_d$  趋于 0, 可化为等效的渐近稳定问题  $\dot{e} + f(\dot{e}, e, u, y, \dot{y}_d, \ddot{y}_d) = 0$ , 其中  $e$  及  $\dot{e}$  为状态分量。

我们在前面通过线性化处理, 已将非线性系统(9.1)变成了完全线性化系统(9.2)式, 或含零动态系统的部分线性化系统(9.4)式。下面来考虑采用什么样的控制律, 能够实现系统的稳定调节和渐近跟踪。

在式(9.6)中, 令

$$v = -k_{r-1}y^{(k-1)} - \dots - k_1\dot{y} - k_0y$$

选择  $k_i$  使多项式:

$$k(s) = s^r + k_{r-1}s^{r-1} + \dots + k_1s + k_0 \quad (9.11)$$

的根全部严格地位于复平面的左半部。则实际系统的控制输入可由(9.6)式得到为:

$$u(x) = \frac{1}{L_g L_f^{r-1} y} [-L_f y - k_{r-1}y^{(r-1)} + \dots - k_1\dot{y} - k_0y] \quad (9.12)$$

**定理 9.3** 设非线性系统(9.1)的关系度为  $r$ , 且其零动态子系统是局部渐近稳定的, 则选择控制律如(9.12)式, 能保证闭环系统是局部渐近稳定的。

该定理的证明可见文献[7]。显然, 将(9.12)式代入(9.2)式, 即可得线性化系统的状态方程。其传递函数为

$$G(s) = \frac{1}{s^r + k_{r-1}s^{r-1} + \cdots + k_0}$$

对上式中  $k_i$  进行合理配置, 即可达到优化设计的目的。

对跟踪控制问题, 指定期望轨迹为  $y_d(t)$ , 令

$$Y_d = [y_d, \dot{y}_d, \cdots, y_d^{(r-1)}]^T \quad Y = [y, \dot{y}, \cdots, y^{(r-1)}]^T$$

定义跟踪误差矢量  $E(t) = Y_d(t) - Y(t)$ , 由误差及其各阶导数组成。其中的各分量表示为

$$e_i = Y_d(i) - Y(i) \quad (i = 1, 2, \cdots, r)$$

则类似地有如下定理。

**定理 9.4** 设系统(9.1)的关系度为  $r$  (在所关注的区域内定义并在其中为恒定),  $y_d$  光滑有界, 方程

$$\dot{\Psi} = \omega(y_d, \Psi) \quad \Psi(0) = 0$$

的解  $\Psi$  存在且有界, 而且是一致渐近稳定的。选择  $k_i$  使(9.11)式的根全部位于左半平面内, 则利用控制律

$$u = \frac{1}{L_g L_f^{r-1} y} [-L_f^r y + y_d^{(r)} + k_{r-1}e_r + \cdots + k_0 e_1] \quad (9.13)$$

能使系统的全部状态保持有界, 并使跟踪误差  $E$  指数收敛于零<sup>[3]</sup>。为使  $t=0$  时起, 系统就保持准确跟踪, 则无论采用什么控制律都要求  $y(0) = y_d(0)$ 。

## 9.4 不对称缸电液伺服系统反馈线性化跟踪控制

### 9.4.1 系统分析与设计

考虑不对称缸弹簧质量系统, 如图 9-1 所示, 其数学方程描述为:

$$\begin{cases} Q_1 = A_1 \dot{x}_p + \left( \frac{v_h + A_1(x_p + L_a)}{\beta_e} \right) \dot{P}_1 \\ Q_2 = A_2 \dot{x}_p - \left( \frac{v_h + A_2(L_a - x_p)}{\beta_e} \right) \dot{P}_2 \end{cases} \quad (9.14)$$

$$P_1 A_1 - P_2 A_2 = m \ddot{x}_p + B \dot{x}_p + K_f x_p \quad (9.15)$$

其中:  $Q_1$ 、 $Q_2$  为伺服缸两腔的流量;  $A_1$ 、 $A_2$  分别为两腔有效面积;  $P_1$ 、 $P_2$  为两腔压力;  $x_p$  是以液压缸中位为零点的活塞位移;  $v_h$  是伺服阀到液压缸之间的等效容积;  $2L_a$  是油缸有效行程;  $m$  为等效质量;  $B$  为运动阻尼;  $K_f$  是弹性系数;  $\beta_e$  为油液弹性模量; 图中  $P_s$  为系统压力;  $P_r$  是回油压力, 这里取为零值。

设伺服阀线圈控制电流为  $u$ , 且不考虑伺服阀的动态特性, 则伺服阀的流量方程为:

$$\begin{cases} Q_1 = k_{sv} u \sqrt{P_s - P_1} \\ Q_2 = k_{sv} u \sqrt{P_2} \end{cases} \quad (u > 0)$$




图 9-1 不对称缸弹簧质量系统

$$\begin{cases} Q_1 = k_{sv} u \sqrt{P_1} \\ Q_2 = k_{sv} u \sqrt{P_s - P_2} \end{cases} \quad (u < 0)$$

其中  $k_{sv}$  为伺服阀流量系数(压力流量增量)。

如取

$$\delta(u) = \begin{cases} 1 & (u \geq 0) \\ 0 & (u < 0) \end{cases} \quad (9.16)$$

则上式可写成:

$$\begin{cases} Q_1 = k_{sv} u (\delta(u) \sqrt{P_s - P_1} + \delta(-u) \sqrt{P_1}) \\ Q_2 = k_{sv} u (\delta(u) \sqrt{P_2} + \delta(-u) \sqrt{P_s - P_2}) \end{cases} \quad (9.17)$$

令

$$x = [x_p, \dot{x}_p, P_1, P_2]^T = [x_1, x_2, x_3, x_4]^T$$

则方程(9.14)和(9.15)可写为

$$\dot{x} = \begin{bmatrix} x_2 \\ \frac{1}{m} [(-K_f x_1 - B x_2) + A_1 x_3 - A_2 x_4] \\ \Psi_1 \\ \Psi_2 \end{bmatrix} \quad (9.18)$$

其中:

$$\Psi_1 = \frac{\beta_e}{v_h + A_1(L_a + x_1)} \{-A_1 x_2 + k_{sv} u [\delta(u) \sqrt{P_s - x_3} + \delta(-u) \sqrt{x_3}]\}$$

$$\Psi_2 = \frac{\beta_e}{v_h + A_2(L_a - x_1)} \{A_2 x_2 - k_{sv} u [\delta(u) \sqrt{x_4} + \delta(-u) \sqrt{P_s - x_4}]\}$$

对于位置控制,输出方程为:

$$y = x_1 \quad (9.19)$$

很显然,上述非线性方程分段满足(9.1)式所示仿射非线性系统的结构。这里,仍将其视为仿射非线性系统,系统阶数  $n=4$ 。按照反馈线性化处理步骤,由(9.18)和(9.19)式可以得到:

$$\dot{y} = \dot{x}_1 = x_2 \quad (9.20)$$

$$\ddot{y} = \dot{x}_2 = \frac{1}{m} [-K_f x_1 - B x_2 + A_1 x_3 - A_2 x_4] \quad (9.21)$$

$$\begin{aligned}\ddot{y} &= \dot{x}_2 \\ &= -\frac{K_f}{m}x_2 + \frac{B}{m^2}(K_fx_1 + Bx_2 - A_1x_3 + A_2x_4) + \frac{1}{m}(A_1\Psi_1 - A_2\Psi_2) \quad (9.22)\end{aligned}$$

其中:

$$\begin{aligned}A_1\Psi_1 - A_2\Psi_2 &= -\frac{\beta_e A_1^2 x_2}{v_h + A_1(L_a + x_1)} - \frac{\beta_e A_2^2 x_2}{v_h + A_2(L_a - x_1)} + u\beta_e k_w \\ &\quad \cdot \left[ \frac{A_1}{v_h + A_1(L_a + x_1)} (\delta(u)\sqrt{P_s - x_3} + \delta(-u)\sqrt{x_3}) \right. \\ &\quad \left. + \frac{A_2}{v_h + A_2(L_a - x_1)} (\delta(u)\sqrt{x_4} + \delta(-u)\sqrt{P_s - x_4}) \right]\end{aligned}$$

将上式代回方程(9.22),得

$$\ddot{y} = f(x) + g(x)u \quad (9.23)$$

其中:

$$\begin{aligned}f(x) &= -\frac{K_f}{m}x_2 + \frac{B}{x^2}(K_fx_1 + Bx_2 - A_1x_3 + A_2x_4) \\ &\quad - \frac{\beta_e x_2}{m} \left[ \frac{A_1^2}{v_h + A_1(L_a + x_1)} + \frac{A_2^2}{v_h + A_2(L_a - x_1)} \right] \\ g(x) &= \frac{\beta_e k_w}{m} \left[ \frac{A_1}{v_h + A_1(L_a + x_1)} (\delta(u)\sqrt{P_s - x_3} + \delta(-u)\sqrt{x_3}) \right. \\ &\quad \left. + \frac{A_2}{v_h + A_2(L_a - x_1)} (\delta(u)\sqrt{x_4} + \delta(-u)\sqrt{P_s - x_4}) \right]\end{aligned}$$

显然,由于系统关系度  $r=3 < n=4$ , 这里就存在零动态子系统的稳定性问题。为此,必须寻找一个微分同胚变换,即寻找另一组非线性方程,将(9.18)式转化为线性规范型形式。这项工作须求解偏微分方程组,且要求技巧较高。工程上一种简单的处理办法是假定零动态子系统是稳定的,然后依据该假设设计控制律,如果控制效果是渐近稳定的,则认为假定成立。对上面的问题,考虑零动态时有:

$$\begin{cases} \dot{y} = 0 \\ \dot{y} = 0 \\ \ddot{y} = 0 \end{cases} \quad \begin{cases} x_2 = 0 \\ A_1x_3 - A_2x_4 = K_fx_1 \\ A_1\dot{x}_3 - A_2\dot{x}_4 = 0 \\ u = 0 \end{cases} \quad (9.24)$$

显然,当  $u=0$  时,  $x_2=0$ , 则  $x_1$  渐近趋于常量;  $x_3, x_4$  按(9.24)式的规则渐近趋于常值;且  $A_1x_3 - A_2x_4 = K_fx_1$  最终趋于稳定是由力平衡方程决定的。所以,由上面简单的分析可以认为系统(9.20)~(9.22)的零动态渐近稳定。

#### 9.4.2 仿真研究

由于统性化后的系统为三阶纯积分环节,对稳定调节器问题,可由定理 9.3 即(9.12)式直接构造极点配置控制律;对跟踪问题,则由定理 9.4 即式(9.13)来构造控制律。设系统的期望跟踪轨迹为  $r$ , 则跟踪控制律为

$$v(x) = r^{(3)} + k_2(r^{(2)} - y^{(2)}) + k_1(r^{(1)} - y^{(1)}) + k_0(r - y) \quad (9.25)$$

其中系数  $k_i$  满足 Hurwitz 多项式  $s^3 + k_2s^2 + k_1s + k_0 = 0$ , 可由零极点配置或 LQR 来求解。如对三阶线性系统, 有

$$A = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix} \quad B = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}$$

设定正定阵  $Q, R$ , 取反馈控制

$$u_f = -k_2\dot{y} - k_1\dot{y} - k_0y = -KY \quad (9.26)$$

令  $A^TP + PA = -Q$ , 求解  $P$ , 则  $K = R^{-1}PB$ 。

结合(9.23)式, 可得实际控制输入量为:

$$u(x) = \frac{v(x) - f(x)}{g(x)} \quad (9.27)$$

对阶跃输入,  $r$  各阶导数为零, 则系统的闭环传函为:

$$\frac{k_0}{s^3 + k_2s^2 + k_1s + k_0} \quad (9.28)$$

由于研究的系统是三阶系统, 因此也可以根据 ITAE 准则进行最优化设计<sup>[222]</sup>, 即可取:

$$k_1 = k_2^2\alpha, \quad k_0 = k_2^3\beta, \quad \alpha = 0.707, \quad \beta = 0.1865$$

其中  $k_2$  与上升时间  $t_r$  的关系为:  $k_2 = 5.5/t_r$ 。若取上升时间为  $t_r = 0.11s$ , 则控制器的各参数可取为:

$$k_2 = 50.0, \quad k_1 = 1767.5, \quad k_0 = 23312.0$$

跟踪控制系统设计如图 9-2 所示, 为物理实现方便, 先取输入  $r$  的三阶导数, 低阶导数由积分器实现。




图 9-2 电液伺服跟踪控制系统框图

仿真中, 控制量  $u$  为电液伺服阀的控制电流信号, 为真实起见, 对控制信号作限幅处理  $\pm 30mA$ 。值得注意的是, 一般反馈线性化控制多由计算机实现, 因此为提高系统的可靠性, 被控系统多由模拟环节构成 BIBO 系统。对电液位置伺服系统而言, 必须有模拟的位置闭环, 简单地可取为比例环节  $K_p$ 。但是, 为保证反馈线性化控制策略的一致性, 求出的控制量应加上反馈信号并除  $K_p$ , 以便保证非线性系统的实际控制输入仍由反馈线性化方程决定。这种方法由于从结构上增加了一个模拟闭环, 保证了计算机控制系统的稳定性。

本节进行了两类仿真研究, 一是直接针对非线性系统模型, 进行 PID 控制仿真, PID 参数分别为  $k_p = 1.0, k_i = 0.01, k_d = 0.02$ ; 二是采用反馈线性化控制方案进行仿真。不对称缸系统的参数如表 9-1 所示<sup>[128]</sup>。

表 9-1 不对称缸系统参数

参数	数值	参数	数值
$A_1$	$4.9742\text{e}^{-4}\text{m}^2$	$K_f$	$160\text{N/m}$
$A_2$	$3.0064\text{e}^{-4}\text{m}^2$	$B$	$70.051\text{Ns/m}$
$v_h$	$8.4574\text{e}^{-6}\text{m}^3$	$k_{sv}$	$3.123\text{e}^{-5}\text{m}^3/\text{A}\sqrt{\text{Pa}\cdot\text{s}}$
$L_a$	$0.0533\text{m}$	$P_r$	$21\text{MPa}$
$m$	$45.36\text{kg}$	$\beta_e$	$1000\text{MPa}$

图 9-3 是传统 PID 控制方法对幅值为 30mm 方波输入的响应情况。由图可知,下降沿的控制较上升沿好,反映了不对称油缸系统运动的不对称性。图 9-4 是对振幅为 30mm 频率为 50rad/s 的正弦输入信号的跟踪响应情况。可以看出,跟踪波形存在较大的响应误差和一定的波形失真。




图 9-3 PID 控制方波跟踪结果




图 9-4 PID 控制正弦波跟踪结果

改变输入信号振幅、频率及 PID 参数,我们可以得出如下结论:

①单纯采用比例控制时,阶跃响应振荡大,正弦响应波形会畸变。

②PID 控制对低频小幅值输入信号有效,合理的参数配置可以在一定精度上,实现对特定信号的跟踪。

③PID 控制器参数与输入信号的幅值关系很大,设置不当易引起发散,表现出非线性系统特有的特征;同时正弦信号跟踪有差。

反馈线性化控制由 ITAE 准则配置闭环传递函数。图 9-5 是系统对方波输入的控制结果。由图可见,由于系统已配置成线性系统,所以上升沿与下降沿的响应完全相同,与图 9-3 相比,上升沿的超调量也明显减小。图 9-6 是对幅值为 30mm 频率为 50rad/s 的正弦波的跟踪结果,可以看出,稳态误差接近为零。如果不考虑系统的物理限制,理论上这种反馈线性化控制方案可以实现对任意频率和幅值的正弦信号的无差跟踪。




图 9-5 反馈线性化控制方波跟踪结果




图 9-6 反馈线性化控制正弦波跟踪结果

上述仿真结果均基于精确已知的系统模型。也就是说,在系统模型及参数精确已知的小,由图 9-2 的控制结构,采用定理 9.4 的控制律,可以实现对已知周期信号的稳态无差跟踪;而阶跃控制性能则由闭环传递函数的零极点配置决定。但是,如果在反馈线性化处理中,存在参数估计误差或系统参数发生时变,理论上必然会产生模型失配,从而



导致控制误差。我们分别考查了弹簧刚度、运动质量、油液弹性模量存在正向 20% 估计偏差时的情况,发现均存在不同程度的控制误差。

图 9-7 是油液弹性模量估计为 1200MPa 时,系统对正弦波的跟踪结果。由图可见,由于模型失配,约存在 25% 左右的控制误差;但与传统 PID 控制方法相比,跟踪精度仍有明显提高。




图 9-7 模型失配时反馈线性化控制正弦波跟踪结果

## 9.5 神经网络参数在线自适应补偿控制

### 9.5.1 电液伺服系统不确定参数神经网络在线补偿方法

精确反馈线性化控制的前提是基于对系统模型的精确掌握,包括模型结构和参数,即要求系统是确定已知的。然而,现实系统中可能存在许多不确定的因素,如参数不确定、高频未建模动态(结构颤动)、低频未建模动态(库仑摩擦)、测量噪声、采样延迟和计算舍入误差等等。在进行控制系统设计时,忽略这些不确定因素的影响,必然导致控制性能下降,严重时还会影响控制系统的稳定性。文献[223]针对死区等非参数不确定的影响进行了研究。本节主要针对电液伺服系统的参数不确定性,进行自适应补偿控制研究。

对于(9.18)式所描述的电液伺服系统,不确定参数主要指油液弹性模量、等效运动质量和弹簧刚度等。一般而言,对等效运动质量和弹簧刚度可以做到比较精确的估计,而油液弹性模量  $\beta_e$  的取值范围却很大,一般为 700~1400MPa。这时采用精确反馈线性化控制,虽然阶跃响应不会产生明显的稳态误差,但是在轨迹跟踪问题上会产生稳态跟踪误差,如图 9-7 所示。因此,如何选取油液弹性模量  $\beta_e$  是电液伺服系统设计中不可忽视的问题。本节就以油液弹性模量为例,来说明电液伺服系统不确定参数的在线补偿控制方法。

设系统未知的油液弹性模量为  $\beta_{e0}$ ,其初始估计值为  $\beta_e$ ,令估计误差为  $\Delta\beta_e = \beta_{e0} - \beta_e$ ,则由(9.23)式可得:

$$\Delta f(x) = f(x, \beta_{e0}) - f(x, \beta_e)$$

$$= -\frac{\Delta\beta_e x_2}{m} \left[ \frac{A_1^2}{v_h + A_1(L_a + x_1)} + \frac{A_2^2}{v_h + A_2(L_a - x_1)} \right] \quad (9.29)$$

$$\begin{aligned} \Delta g(x) &= g(x, \beta_{e0}) - g(x, \beta_e) \\ &= \frac{\Delta\beta_e k_{sv}}{m} \left[ \frac{A_1}{v_h + A_1(L_a + x_1)} (\delta(u) \sqrt{P_s - x_3} + \delta(-u) \sqrt{x_3}) \right. \\ &\quad \left. + \frac{A_2}{v_h + A_2(L_a - x_1)} (\delta(u) \sqrt{x_4} + \delta(-u) \sqrt{P_s - x_4}) \right] \end{aligned} \quad (9.30)$$

由(9.27)式可知,系统的理想控制信号为:

$$\begin{aligned} u(x) &= \frac{v(x) - f(x, \beta_{e0})}{g(x, \beta_{e0})} = \frac{v(x) - f(x, \beta_e) - \Delta f(x)}{g(x, \beta_e) + \Delta g(x)} \\ &= \frac{v(x) - f(x, \beta_e) - \Delta f(x)}{g(x, \beta_e) \left[ 1 + \frac{\Delta g(x)}{g(x, \beta_e)} \right]} \\ &= \frac{v(x) - f(x, \beta_e)}{g(x, \beta_e) \left[ 1 + \frac{\Delta g(x)}{g(x, \beta_e)} \right]} - \frac{\Delta f(x)/g(x, \beta_e)}{\left[ 1 + \frac{\Delta g(x)}{g(x, \beta_e)} \right]} \\ &= \frac{v(x) - f(x, \beta_e)}{g(x, \beta_e)(1+a)} + \left( 1 - \frac{1}{1+a} \right) K_p(x) \end{aligned} \quad (9.31)$$

其中  $a = \Delta\beta_e/\beta_e$  表示油液弹性模量的相对变化量;  $K_p(x)$  是与  $\beta_e$  的变化无关而仅与系统状态有关的函数,其表达式为

$$K_p(x) = \frac{x_2}{k_{sv}} \cdot \frac{\frac{A_1^2}{v_h + A_1(L_a + x_1)} + \frac{A_2^2}{v_h + A_2(L_a - x_1)}}{\frac{A_1 q_1}{v_h + A_1(L_a + x_1)} + \frac{A_2 q_2}{v_h + A_2(L_a - x_1)}} \quad (9.32)$$

其中:

$$\begin{aligned} q_1 &= \delta(u) \sqrt{P_s - x_3} + \delta(-u) \sqrt{x_3} \\ q_2 &= \delta(u) \sqrt{x_4} + \delta(-u) \sqrt{P_s - x_4} \end{aligned}$$

此时,引起的控制量偏差为:

$$\begin{aligned} \Delta u(x) &= u(x, \beta_{e0}) - u(x, \beta_e) \\ &= \frac{v(x) - f(x, \beta_e)}{g(x, \beta_e)(1+a)} + \frac{a}{1+a} K_p(x) - \frac{v(x) - f(x, \beta_e)}{g(x, \beta_e)} \\ &= b [K_p(x) - u(x, \beta_e)] \end{aligned} \quad (9.33)$$

其中  $b = a/(1+a)$ 。可见实际控制输入与理想控制输入不等,因而必然产生稳态误差。对阶跃输入,由于系统的开环增益相当大  $k_0 = 23312.0$ ,若忽略油缸内泄漏,则有  $\Delta u(x) = 0$ ,因而不会产生稳态误差;而对正弦信号,当  $b \neq 0$  时,总有  $\Delta u(x) \neq 0$ ,所以跟踪误差始终存在。

以上仅讨论了油液弹性模量的变化对控制输入的影响。当系统中不确定参量较多时,  $\Delta u(x)$  将会更加复杂。

为了尽量减小液压系统参数不确定对控制性能的影响,采用反馈线性化控制技术时,应综合考虑估计值的偏差方向。实验中发现,当运动质量和弹簧刚度的估计偏差方向相

同,即同时偏大或偏小,弹簧刚度和油液弹性模量的偏差方向相反时,可以在一定程度上减小参数偏差的影响。

另外,在式(9.33)中, $b$  是未知的确定常数,因此  $\Delta u(x)$  可视为状态变量的未知函数。我们知道,神经网络具有辨识未知函数的能力,并能较好地处理系统的不确定性。因此,若能利用神经网络来辨识系统因不确定因素引起的控制量偏差,并将其作为补偿控制量直接叠加在系统控制端,共同对系统实施控制作用,则可能补偿不确定性因素对控制性能的影响。基于这一思想,本节采用的神经网络补偿控制结构如图 9-8 所示,网络的输入向量由系统状态即位置、速度、加速度等组成。

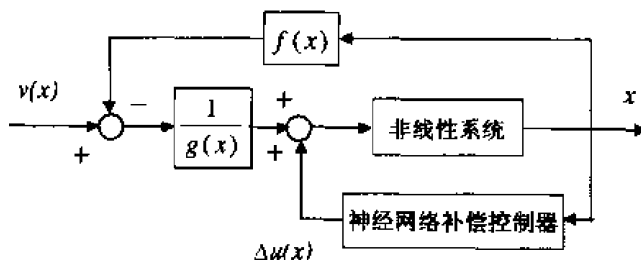


图 9-8 神经网络补偿控制结构

本节只考虑油液弹性模量不确定时的情况, $\beta_{e0}$  的取值范围已知,因而  $a$ 、 $b$  的变化范围也可根据估计的  $\beta_e$  得到。只要能通过在线辨识得到  $b$ ,就可以直接利用(9.33)式来求取神经网络自适应补偿控制器的输出。神经网络权值的构造和学习可依据第五章的方法进行,令

$$w = w_p + w_i + w_d$$

则由 BP 学习算法可得权值调节规则为

$$w_p = k_p e \operatorname{sgn}(\partial y / \partial u)$$

$$\Delta w_i = k_i e \operatorname{sgn}(\partial y / \partial u)$$

$$w_d = k_d |\dot{e}| \operatorname{sgn}(e) \operatorname{sgn}(\partial y / \partial u)$$

其中: $k_p$ 、 $k_i$ 、 $k_d$  为相应的调节因子; $e$ 、 $\dot{e}$  分别为位置误差和速度误差。神经网络补偿控制量由(9.33)式直接给出为

$$\Delta u(x) = w[K_p(x) - u(x, \beta_e)] \quad (9.34)$$

则系统的实际控制量即可由下式求得

$$u = u(x, \beta_e) + \Delta u(x) \quad (9.35)$$

### 9.5.2 仿真结果

针对图 9-7 由于油液弹性模量估计有偏产生的正弦跟踪有差的情况,采用(9.34)和(9.35)式进行神经网络在线补偿控制。

为保证补偿控制器不会对系统的稳定性构成威胁,对神经网络补偿控制器的输出进行限幅。设油液弹性模量的变化范围为  $\beta_{e0} \in [700, 1400]$  MPa, 其估计值为  $\beta_e = 1200$  MPa, 则不确定参数的变化范围为  $a \in [-5/12, 1/6]$ ,  $b \in [-5/7, 1/7]$ 。

图 9-9 给出了采用神经网络补偿控制的正弦波跟踪结果,稳态误差约为 5%,与图

9-7相比,控制效果有明显改善。




图 9-9 神经网络在线自适应补偿控制结果

## 9.6 本章小结

不对称缸电液伺服系统存在多种非线性和不确定性因素,采用传统的工作点线性化及线性控制方法难以达到满意的跟踪控制效果。本章首先讨论了非线性系统反馈线性化控制策略,及其在非线性不对称缸电液伺服系统中的应用情况。研究表明,对不对称缸电液伺服系统,在系统模型及参数精确已知的情况下,反馈线性化控制方法可以实现对已知周期信号的稳定无差跟踪。

然而,不对称缸系统的参数不确定性直接影响了反馈线性化控制方法的实际应用。为此,本章提出了神经网络参数在线自适应控制补偿思想。并针对电液伺服系统油液弹性模量等不确定因素的影响,设计了不确定参数的神经网络自适应补偿控制器。仿真结果表明神经网络补偿控制方法有效可行,明显提高了系统的跟踪性能。为反馈线性化控制技术在实际非线性电液伺服系统中的应用创造了条件。

## 第十章 液压系统压力脉动神经网络 自适应主动控制

### 10.1 引言

随着液压系统向高压、高精度、低噪声的方向发展,液压系统的压力脉动问题显得愈发突出。压力脉动主要是流量脉动在系统存在阻抗时产生的。在液压系统中,产生流量脉动的主要根源有两类:一是液压泵,二是执行机构、控制元件及负载。通常,液压系统的压力脉动对系统的工作状态会产生不良影响,其危害主要表现在以下三个方面:

①压力脉动直接导致管路的振动,特别在压力脉动频率与管路的固有频率相等或相近时,会造成系统的共振,使液压系统遭受严重破坏。这是长管道液压系统必须重视的问题。

②压力脉动直接影响系统和元件的工作质量。特别在高频响、高精度电液伺服系统中,压力脉动对系统工作精度的影响很大,有时甚至使系统难以正常工作。

③压力脉动能造成系统管道的振动并辐射噪音,污染周围环境,尤其易对人耳听力造成伤害。

由此可见,控制液压系统的压力脉动,对提高系统的可靠性和工作性能,降低环境污染具有十分重要的意义。一般可从以下两方面入手:

①对由液压泵引起的脉动,从改进液压泵的本身结构出发,尽量降低其输出的流量脉动<sup>[224,225]</sup>。这是液压泵研究的一个方向,对降低系统脉动及泵源噪声都有益处。

②对压力脉动进行衰减和滤波<sup>[226~232]</sup>。

前一种方法由于受到泵体结构特性的影响,很难收到完美的效果;而且执行机构、控制元件及负载引起的流量脉动也并非能通过泵体结构的改进而完全消除。因此,液压系统压力脉动的衰减研究一直受到国内外液压界的广泛重视。主要采用两种方法,一是被动衰减,二是主动衰减。被动衰减又称无源衰减,它是采用脉动衰减器来衰减系统的压力脉动,这是目前采用最多的方法。随着高效脉动衰减器的不断研究开发和应用,被动降脉方法已取得了很大的发展,并对频率较高的压力脉动有较好的衰减效果。但对于低频压力脉动的衰减,这种方法要求脉动衰减器的体积增大,而且脉动衰减器的通用性变差,从而限制了实际使用。这种情况下,液压系统脉动主动衰减控制方法便应运而生。主动脉动衰减方法是近年来兴起的衰减脉动的新方法,又称有源脉动衰减法。

液压系统主动脉动控制方法的基本原理是:利用外界的脉动源产生的压力脉动波与原系统的压力脉动波产生相消性干涉,从而消减原系统的压力脉动。随着计算机控制技术及现代控制理论的迅猛发展,液压有源主动脉动衰减控制已引起人们越来越多的重视与研究。

在压力脉动主动控制研究中,目前应用较多的是基于 LMS 算法的横向自适应滤波方法。由于 LMS 算法及其改进算法均是建立在线性系统的基础上,而液压系统中存在

着复杂的非线性和时变不确定性因素,系统参数受外界环境的影响很大,因而这种方法对液压系统压力脉动的控制效果是非常有限的。随着神经网络理论与技术的发展,神经网络在自适应滤波与控制中的应用越来越广<sup>[18,44]</sup>,将神经网络引入主动消声控制系统也进行了研究<sup>[233,234]</sup>,但 BP 网络属全局逼近网络,学习缓慢,在理想轨迹附近的泛化能力往往不如局部逼近网络。因此,本章根据神经网络的特点和液压系统压力脉动主动控制的特点,提出基于 B 样条神经网络的液压系统压力脉动主动控制方法<sup>[235]</sup>。仿真和实验研究表明,该系统具有良好的降脉性能,完全可用于实际应用。

## 10.2 液压系统压力脉动主动控制原理

### 10.2.1 脉动波相消性干涉的原理和实现条件<sup>[236,237]</sup>

液压有源脉动控制的原理是建立在两列脉动相消干涉的基础上,即利用次级脉动源产生一系列和初级脉动源幅值相等、相位相反的脉动波,使两列脉动波相迭加而抵消。

在液压有源主动脉动控制中,脉动的频率远小于液压管道的截止频率,则初级脉动源为平面波。波的干涉是波在迭加中的一种特殊情况,设有两列具有相同频率、固定相位差的波叠加,到达系统管道某位置的两列波分别为

$$P_1 = P_{1A} \cos(\omega t - \varphi_1) \quad (10.1)$$

$$P_2 = P_{2A} \cos(\omega t - \varphi_2) \quad (10.2)$$

由叠加原理,合成的压力为

$$\begin{aligned} P &= P_1 + P_2 = P_{1A} \cos(\omega t - \varphi_1) + P_{2A} \cos(\omega t - \varphi_2) \\ &= P_A \cos(\omega t - \varphi) \end{aligned} \quad (10.3)$$

其中:

$$\begin{aligned} P_A &= \sqrt{P_{1A}^2 + P_{2A}^2 + 2P_{1A}P_{2A}\cos(\varphi_2 - \varphi_1)} \\ \varphi &= \tan^{-1} \frac{P_{1A}\sin\varphi_1 + P_{2A}\sin\varphi_2}{P_{1A}\cos\varphi_1 + P_{2A}\cos\varphi_2} \end{aligned}$$

而合成压力的平均能量密度为

$$E = E_1 + E_2 - \frac{P_{1A}P_{2A}}{\rho a^2} \cos\varphi \quad (10.4)$$

其中: $\rho$  为流体密度; $a$  为压力波传播速度。

上式表明,合成的压力仍是一个频率相同的脉动波,但合成压力波的振幅不等于两列压力波的振幅之和,而是与两列压力波的相位有关。合成压力波的平均能量密度也与两列压力波的相位有关。当两列压力波产生干涉现象时,如果相位差  $\Psi = \varphi_2 - \varphi_1 = \pm \pi$ , 则有:

$$\begin{aligned} P_A &= P_{1A} - P_{2A} \\ E &= E_1 + E_2 - \frac{P_{1A}P_{2A}}{\rho a^2} \end{aligned}$$

表明两列脉动波是相消性干涉,其合成的压力波幅值是两列压力波幅值之差,平均能量密度为两列平均密度之和再减去  $\frac{P_{1A}P_{2A}}{\rho a^2}$ 。如果  $P_{1A} = P_{2A}$ , 则合成的压力波幅值及平均能

量密度均为零。

可以证明,当频率不同,或不具有固定相位差或为无规则相位差时,压力波的叠加不会产生相消性干涉。由此可见,两列压力波呈相消性干涉必须满足:

- ① 频率相同。
- ② 两列波相位差为 180 度。
- ③ 压力波的相位随时间作规则变化。

这是有源脉动控制的基本出发点,同时也是各种有源噪声及脉动控制系统所必须满足的基本条件。

### 10.2.2 液压系统压力脉动主动控制原理

液压系统有源脉动控制按所用次级脉动源的数目可分为单脉动源结构和多脉动源结构。由于单脉动源结构简单易行,目前液压系统有源脉动控制基本为单脉动源结构,如图 10-1 所示。其中  $S$  为初级脉动源,  $L_s$  为次级脉动源。

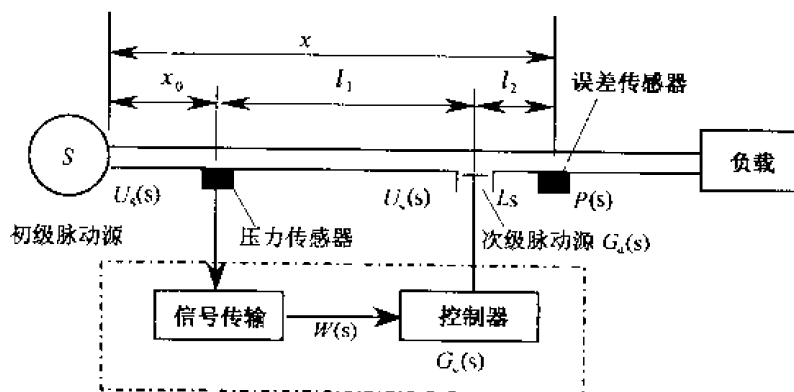


图 10-1 液压系统压力脉动主动控制原理框图

选取坐标系使管道下游为  $X$  轴正方向,初级脉动源位于  $x=0$  处,传播面积等于管道的截面积  $A$ ,脉动速度为  $u_s(t)$ ;次级脉动源  $L_s$  位于  $x=x_0+l_1=x_1$  处,脉动速度为  $u_c(t)$ ;管道截面积为  $A_1$ 。假定液体为理想介质,略去时间因子  $\exp(-i\omega t)$ ,由于压力脉动频率远小于管道的一阶截止频率,则初级脉动源在管道中的脉动压力可表示为<sup>[238]</sup>

$$P_P = \rho a u_s \exp(ikx) \quad (10.5)$$

相应管道中各点的平均能量密度为:

$$E_P = \frac{\overline{P_P^2}}{\rho a^2} = \frac{1}{2} \rho |u_s|^2 \quad (10.6)$$

次级脉动源既向管道下游传播压力,又向管道上游传播压力。向上游传播的压力为:

$$P_{IP} = \rho a u_c \frac{A_1}{2A} \exp[-ik(x-x_1)] \quad (10.7)$$

而向下游传播的压力为:

$$P_{IS} = \rho a u_c \frac{A_1}{2A} \exp[ik(x-x_1)] \quad (10.8)$$

于是,管道下游的总压力脉动为:

$$\begin{aligned}
 P_a(x) &= (P_P + P_{LS})|_{x > x_0 + l_1} \\
 &= \rho a u_s \exp(ikx) + \rho a u_c \frac{A_1}{2A} \exp[ik(x - x_1)] \quad (10.9)
 \end{aligned}$$

要使管道下游完全消除脉动,即要求  $P(x) = 0$ ,则由上式可得,次级源速度与初级源速度之间的关系为

$$u_c = -u_s \frac{2A}{A_1} \exp(ikx_1) \quad (10.10)$$

与此同时,管道上游的脉动压力为:

$$\begin{aligned}
 P_u &= P_P + P_{LP}|_{x < x_0 + l_1} \\
 &= \rho a u_s \exp(ikx) + \rho a u_c \frac{A_1}{2A} \exp[-ik(x - x_1)] \quad (10.11)
 \end{aligned}$$

将(10.10)式代入上式,得

$$\begin{aligned}
 P_u(x) &= \rho a u_s \exp(ikx) \{1 - \exp[-i2k(x - x_1)]\} \\
 &= i2\rho a u_s \sin[k(x - x_0 - l_1)] \exp[ik(x_0 + l_1)] \quad (10.12)
 \end{aligned}$$

这表明管道上游的脉动压力为一驻波,各点相应的平均能量密度为:

$$F_{ux} = \frac{\overline{P_u^2}}{\rho a^2} = 2\rho |u_s|^2 \sin^2[k(x - x_0 + l_1)] \quad (10.13)$$

对上游各点的平均能量密度进行平均,可得:

$$E_u = \frac{1}{x_0 + l_1} \int_0^{x_0 + l_1} E_{ux} dx = \rho |u_s|^2 \left[ 1 - \frac{\sin 2k(x_0 + l_1)}{2k(x_0 + l_1)} \right] \quad (10.14)$$

将上式与(10.6)式进行比较,可得上游平均能量密度与初级源在相应管道中造成的平均能量密度之间的关系为

$$E_u = 2E_P \left[ 1 - \frac{\sin 2k(x_0 + l_1)}{2k(x_0 + l_1)} \right] \quad (10.15)$$

上述分析表明,当次级源的速度与初级源的速度之间满足(10.10)式的要求时,在下游管道可实现完全的脉动消除;而在上游,平均能量密度与未控制之前该量之间的关系为初级、次级源间距离的函数。当  $x_0 + l_1$  较大时,即初级源  $S$  与次级源  $L_S$  相距很远时,  $E_u \rightarrow 2E_P$ ,这表明下游的能量全部“反射”回了上游,并直接与上游的能量相加。

以上理论分析,均假设液体为理想介质,即不考虑液体的压缩性与粘性。实际的液体均有可压缩性与粘性,而且是时变的。因此,研究压力脉动主动控制策略时,要考虑到这些因素的影响。

如图 10-1 所示,液压有源脉动控制的工作原理是,由初级脉动源旁边的压力传感器检测到管道中的压力脉动信号后,经过信号处理,送入控制器,输出控制信号驱动次级脉动源工作,产生次级压力脉动信号,并与管道中的初级压力脉动信号相互抵消,以衰减下游压力脉动。

设初级脉动源管道内的流速脉动为  $u_s(t)$ ,管路上并联的次级脉动源的流速脉动为  $u_c(t)$ ,在  $x = x_0$  处检测的信号为  $w(t)$ ,在管道的位置  $x$  处的压力脉动为  $P(t, x)$ ,则在频域内,系统的基本方程可表示如下:

$$U_c(s) = G_a(s) G_c(s) W(s) \quad (10.16)$$



$$W(s) = W_s(s) + W_c(s) = G_{s,w}(s)U_s(s) + G_{c,w}(s)U_c(s) \quad (10.17)$$

$$P(s, x) = P_s(s) + P_c(s) = G_{s,p}(s)U_s(s) + G_{c,p}(s)U_c(s) \quad (10.18)$$

其中:  $G_c(s)$  为控制器的传递函数;  $G_a(s)$  为次级脉动源的传递函数;  $W(s)$ 、 $U_c(s)$ 、 $U_s(s)$  分别为  $w(t)$ 、 $u_c(t)$ 、 $u_s(t)$  的拉氏变换;  $w_s(t)$  为  $u_s(t)$  单独作用下产生的控制器输入信号;  $w_c(t)$  为  $u_c(t)$  单独作用下产生的控制器输入信号;  $p_s(t, x)$  为  $u_s(t)$  单独作用下产生的脉动信号;  $p_c(t, x)$  为  $u_c(t)$  单独作用下产生的脉动信号;  $G_{s,w}(s)$  为  $W_s(s)$  与  $U_s(s)$  之比;  $G_{c,w}(s)$  为  $W_c(s)$  与  $U_c(s)$  之比;  $G_{s,p}(s)$  为  $P_s(s, x)$  与  $U_s(s)$  之比;  $G_{c,p}(s)$  为  $P_c(s, x)$  与  $U_c(s)$  之比。

由(10.16)~(10.18)式可得,在  $x \geq x_0 + l_1$  的管道内,压力脉动  $P(s, x)$  与初级源流速脉动  $U_s(s)$  的关系为

$$P(s, x) = \frac{G_s(s)G_{c,p}(s)G_{s,w}(s) + G_{s,p}(s) - G_s(s)G_{c,w}(s)G_{s,p}(s)}{1 - G_s(s)G_{c,w}(s)} U_s(s) \quad (10.19)$$

其中  $G_s(s) = G_c(s)G_a(s)$ 。

为使在  $x \geq x_0 + l_1$  的管道内的压力脉动  $P(s, x) = 0$ , 则应使控制器的传函为

$$G_c(s) = \frac{G_{s,p}(s)/G_a(s)}{G_{c,w}(s)G_{s,p}(s) - G_{c,p}(s)G_{s,w}(s)} \quad (10.20)$$

如果控制系统采用模拟信号处理系统或固定参数数字滤波处理系统,那么要准确得到  $G_c(s)$ ,就需求得各个组件的精确传递函数,而且液压系统的特性一旦发生变化,就必须重新辨识模型。因此,上述液压有源脉动控制系统的缺点是当有关组件的传递函数不准确或液压系统的工况条件发生变化时,要保证系统能衰减一定的压力脉动,就得重新调整控制参数。我们知道,液压系统的压力脉动,受系统工作状态、元件参数、油液粘度、温度等参数的影响,具有一定的时变特性;此外,控制系统中电子线路参数、次级脉动源的频率特性等也具有时变性,因此,上述有源脉动控制系统具有一定的局限性。为了使有源脉动控制系统具有稳定的压力脉动衰减效果,目前液压有源脉动控制系统一般采用自适应控制技术。

### 10.3 自适应压力脉动主动控制系统模型

由于受液压系统及控制系统中各组件尺寸参数及安装位置、油液粘度、控制系统电子线路的参数及次级脉动源的频率特性等的影响,采用模拟信号处理系统或固定参数的数字滤波系统,液压系统的压力脉动控制均得不到较好的降脉效果,甚至控制系统不能稳定工作。因此,有源脉动控制目前基本上采用自适应技术。由此形成了有源自适应脉动控制(Active Adaptive Pulsation Control,简称 AAPC)。

AAPC 系统的关键是自适应控制方法及相应的自适应控制算法,它直控影响控制系统的压力脉动衰减量。在控制方法中,只要脉动是可预测的、控制器是因果的,则前馈控制是一种很有效的控制方法。迄今为止,大多数主动噪声及脉动控制算法均采用前馈控制算法<sup>[227~232]</sup>。另外,反馈控制也是一种可行的方法。反馈控制方法不需要测量原始噪声或脉动,但由于噪声或压力脉动的影响,纯反馈控制的稳定性较难保证<sup>[239]</sup>。因此,本

章将研究前馈控制策略及其算法,并将其应用于液压有源自适应脉动控制。

本节提出的自适应有源降脉控制系统模型如图 10-2 所示,这是一个采用单次级脉动源的自适应降脉系统,主要由脉动源、滤波电路、控制器和伺服阀组成。系统的工作原理是:初级压力传感器检测脉动信号,并作为自适应滤波器的参考输入,经自适应控制器处理后,驱动次级脉动源工作,产生附加压力脉动信号,以便与管道中的原始压力脉动相互抵消,从而起到降脉的作用。为了使下游的压力脉动衰减量最大,由误差传感器检测下游处的脉动信号,并作为误差信号反馈给控制器,不断修正控制器参数,调整次级脉动源的大小,最终使系统中的压力脉动减少到最小并保持控制系统稳定。

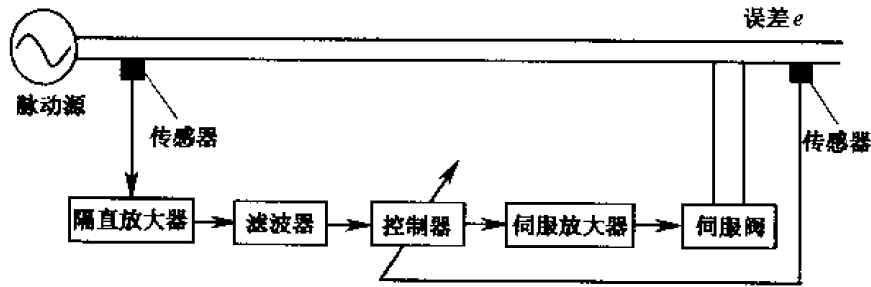


图 10-2 自适应有源脉动控制系统

AAPC 系统的等效框图如图 10-3 所示,其中  $p(k)$  为脉动源压力; $H_{pe}(z)$ 为初级脉动源至误差传感器的模型; $H_f(z)$ 为初级脉动源至控制器的传函; $H(z)$ 为控制器的传函; $H_w(z)$ 为次级脉动源至误差传感器的模型; $H_e(z)$ 为次级脉动源至初级脉动源的模型; $x(k)$ 为自适应控制器的参考输入; $y(k)$ 为次级脉动源的输入信号; $s(k)$ 为误差传感器处的脉动信号。图中虚线表示次级脉动源的反馈作用。即初级压力传感器在感受初级压力脉动的同时,还感受到次级脉动源产生的压力脉动,这对控制系统的稳定性会产生很大影响。




图 10-3 AAPC 系统框图

为了克服或减弱次级脉动源产生的压力脉动信号对初级脉动源产生的参考信号的影响,在拾取初级信号时,通常采取以下两种措施:

①利用相距一定距离的两个压力传感器实时检测出压力脉动的进行波,并将其作为自适应滤波器的参考输入。这种参考信号拾取方法对改善控制系统的稳定性有很大作用。

②直接将初级脉动源-伺服阀的输入信号作为自适应滤波器的参考输入,这样整个系

统中就不存在次级脉动源的反馈作用,在此条件下,再进行自适应控制算法研究。

采用以上措施后,次级脉动源的反馈影响已足够弱,可忽略不计。此时图 10-3 的框图可简化为如图 10-4 所示。




图 10-4 简化后的 AAPC 系统框图

在前馈控制中,由于横向结构 FIR(Finite Impulse Response)滤波器实施方便,最小均方(Least Mean Squares,简称 LMS)算法简单,实时性好,因而在自适应有源噪声控制系统中,多采用基于 LMS 算法的横向自适应滤波器<sup>[227,228]</sup>。在实际应用中,考虑到实施方便,常采用 LMS 的改进算法,如滤波-X 最小均方(FILMS)算法、滤波-X 递推最小二乘(FRLS)算法<sup>[240]</sup>、最小二乘格形(LSL)算法<sup>[228]</sup>等。这些算法的缺点是都需要知道误差通道传函的估计值。而估计值的不准确将使算法收敛步距减小,严重时将引起控制系统的不稳定。目前,误差通道模型的估计有三种方法:(1)离线建模;(2)将误差通道视为一时延通道,进行估计;(3)在线自适应建模。前两种方法的不足之处在于,由于误差通道的特性是时变的,为反映这一变化,不得不经常进行估计,这对工程应用来说很不方便;同时要将延时通道模型估计得很准确也很困难。第三种方法离实际应用还有一段距离。这是由于系统存在多种不确定性和难以描述的非线性,建模困难。对一些复杂系统即使能够建模,其模型也相当复杂,难以在线进行。上述 LMS 及其改进算法应用于这些时变非线性过程时,要达到收敛,需要较多的迭代步数,且容易使控制过程产生振荡,难以满足实际需要。

其实,在液压系统中,管道中流量、压力脉动等都属于分布参数,而且液压系统本身也存在着很多非线性因素,系统参数受外界环境的影响很大,而传统的 FILMS 算法及其改进算法是建立在线性系统基础上的。因此,对液压系统压力脉动的控制效果自然是很有局限的。从本质上看,基于 LMS 算法的横向自适应滤波器可以看成是线性组合器,即相当于线性神经网络模型。而神经网络具有很强的非线性逼近能力。因此,如果能利用神经网络的逼近能力来设计滤波器,那么基于神经网络的自适应滤波器将比基于 LMS 算法的横向自适应滤波器具有更好的逼近非线性函数的能力。

## 10.4 基于 B 样条神经网络的自适应 压力脉动主动控制系统

前已叙及,在传统的自适应控制中,控制器可分为两类:直接自适应控制和间接自适应控制。在间接型自适应控制方法中,需要辨识控制对象的数学模型,然后根据系统的辨识模型来进行控制器设计。FILMS 及其改进算法都属于间接自适应控制,其基本特点是

需要辨识控制对象的模型。在直接型自适应控制方法中,控制系统不需要辨识对象的模型,控制器的参数可以直接依据跟踪误差进行调整,直到把控制对象和参考模型之间的输出误差减少到一定范围为止。它与间接自适应控制不同之处就在于不需要预先或同时辨识对象的模型。在本章研究的液压有源脉动控制中,为避免辨识次级脉动源至误差传感器之间的伺服放大器、伺服阀以及伺服阀出口到误差传感器的模型,我们采用直接型自适应控制器进行控制系统的设计。

自适应控制器由 B 样条神经网络来实现,这样,只要将图 10-4 中的控制器  $H(z)$  用 B 样条神经网络来代替,就构成了基于 B 样条神经网络的液压有源压力脉动控制系统,如图 10-5 所示。B 样条网络的输入输出关系,即控制律为

$$y = W a(x) \quad (10.21)$$

其中  $W$  为网络输出层的权值向量。




图 10-5 基于 B 样条网络的 AAPC 系统框图

控制系统的目标是使误差传感器处的压力脉动达到最小,因此可定义脉动控制系统的目标函数为

$$J = e^2(k) = [d(k) - s(k)]^2 \quad (10.22)$$

B 样条神经网络输出层的权值可采用梯度算法进行修正,学习规则为

$$W(k+1) = W(k) - \beta \frac{\partial J}{\partial W(k)} \quad (10.23)$$

其中

$$\frac{\partial J}{\partial W(k)} = \frac{\partial J}{\partial y(k)} \cdot \frac{\partial y(k)}{\partial W(k)} = \frac{\partial J}{\partial s(k)} \cdot \frac{\partial s(k)}{\partial y(k)} \cdot \frac{\partial y(k)}{\partial W(k)} \quad (10.24)$$

在上式计算中,包含了伺服放大器、伺服阀以及伺服阀出口至误差传感器之间的模型等组成的误差通道的 Jacobi 矩阵  $\partial s(k)/\partial y(k)$ 。对于未知的误差通道,它是未知的。目前有以下两种近似计算方法:

(1) 由于误差未知,可以用输入输出的差商来近似地求得

$$\frac{\partial s(k, y)}{\partial y} \approx \frac{s(k+1, y) - s(k, y)}{y(k+1) - y(k)} \quad (10.25a)$$

或

$$\frac{\partial s(k, y)}{\partial y} \approx \frac{s(k, y + \Delta y) - s(k, y)}{\Delta y} \quad (10.25b)$$

(2) 通过先验知识确定出  $y(k)$  对  $s(k)$  的影响趋势,即

$$\frac{\partial s(k)}{\partial y(k)} = \left| \frac{\partial s(k)}{\partial y(k)} \right| \operatorname{sgn} \left( \frac{\partial s(k)}{\partial y(k)} \right) \quad (10.26)$$

在液压系统压力脉动主动控制系统中,由于误差传感器处的压力脉动是次级脉动源产生的脉动与初级脉动源的共同作用,因而在控制过程中,(10.25)式不容易计算。为此,我们采用第二种估计方法。在图 10-5 所示系统中,当神经网络控制器的输出增加时,次级脉动源产生的附加脉动也相应增加,因此  $\partial s(k)/\partial y(k) = 1$ 。故(10.24)式可写为

$$\begin{aligned}\frac{\partial J}{\partial W(k)} &= \frac{\partial J}{\partial s(k)} \cdot \frac{\partial s(k)}{\partial y(k)} \cdot \frac{\partial y(k)}{\partial W(k)} \\ &= -2e(k) \left| \frac{\partial s(k)}{\partial y(k)} \right| \operatorname{sgn} \left( \frac{\partial s(k)}{\partial y(k)} \right) \frac{\partial y(k)}{\partial W(k)} \\ &= -2e(k) \left| \frac{\partial s(k)}{\partial y(k)} \right| \alpha(k)\end{aligned}\quad (10.27)$$

将上式代入(10.23)式,可得 B 样条神经网络输出层的权值修正规则为

$$W(k+1) = W(k) + \eta e(k) \alpha(k) \quad (10.28)$$

其中  $\eta = 2\beta |\partial s(k)/\partial y(k)|$ 。

在液压系统压力脉动主动控制中,算法的运算量是衡量控制系统性能的一个重要指标。如果计算量大,就会降低控制系统所衰减的脉动频率,而过大的运算量则可能导致控制过程无法收敛,造成控制系统的失稳。研究表明,与自适应控制算法相比,基于 B 样条网络的控制算法的运算量还是能够接受的。

## 10.5 液压系统压力脉动主动控制仿真研究

### 10.5.1 仿真系统设计

仿真所用系统如图 10-5 所示。其中  $H_{pc}(z)$  为初级脉动源至误差传感器之间的模型,称为主通道模型; $H_{sc}(z)$  为伺服放大器、伺服阀及阀出口至误差传感器的管道之间的模型。由于液压系统中某点的压力与流量的函数关系属于分布参数,与整个液压系统的元件特性等因素有关。因此,在仿真中将伺服放大器及伺服阀的模型认为是误差通道  $H_{sc}(z)$  的模型。同样在主通道,用一典型的线性或非线性模型来代替分布参数模型  $H_{pc}(z)$ 。从而使仿真模型相对简化。

还需要说明的是,系统中还有另外两个组件:初级脉动源和次级脉动源。其中初级脉动源即原始压力脉动源,它产生的压力脉动中往往包含有多种频率成分,对所有频率的脉动都进行控制是十分困难的。但是液压系统中的主要脉动成分通常是有限的几个频率成分的叠加,因此,只要将这些脉动成分加以控制,则压力脉动就可大大降低。鉴于此,仿真所用初级脉动信号将采用某一基频及一次倍频所组成的脉动成分。

次级脉动源又称附加脉动源。它是控制系统中的执行机构,用以产生附加脉动。目前次级脉动源主要有以下三种类型:膜片型、活塞型和伺服阀型。其中活塞型及膜片型的结构如图 10-6 所示。它们都需要另外附加驱动装置。优点是多余流量进出液压系统。

伺服阀型次级脉动源利用了伺服阀的高频节流特性,其优点是整个装置比较简单,实施简便,但有多余流量进出系统。根据伺服阀在工作过程中流量相对于系统油液流动方向的不同,伺服阀附加流量脉动的产生有三种型式:旁路分流型、旁路入流型和旁路分流



图 10-6 活塞型及膜片型结构简图

入流复合型。分(入)流型的特点是在工作过程之中,伺服阀存在一定的预开口量,因而始终有流量从系统中流出(入)。其工作原理是,当系统压力脉动的波峰到达阀前时,伺服阀有最大的流量流出(入)系统;而当压力脉动的波谷到达阀前时,经过伺服阀流出(入)的流量最小,从而衰减系统的压力脉动。

分流入流复合型的特点是工作前伺服阀不需要预开口量。其工作过程是,当系统压力脉动的波峰到达阀前时,伺服阀有最大的流量流出系统,而当系统压力脉动的波谷到达阀前时,伺服阀有最大的流量流入系统。

由上面的分析可看出,分流方式的优点是,除了主油路以外,不需附加另外的液压油源,缺点是系统效率降低。入流型及复合型都需要附加油源。在本章研究中,选用伺服阀作次级脉动源,伺服阀与系统的连接采用分流方式,如图 10-7 所示。




图 10-7 伺服阀与系统的连接方式

另外,在液压系统压力脉动主动控制中,最基本和最关键的是控制系统的稳定性和快速收敛性能。对于一个具体的系统来说,这不仅取决于系统结构,而且还取决于所采用的控制算法。不同的算法应用于实际系统时,其稳定性、收敛速度及所获得的脉动衰减量有很大差别。传统的 FLMS 自适应控制算法用于液压系统主动降脉时虽然具有结构简单,实现方便的特点,但液压系统存在的严重非线性及时变特性,使 FLMS 控制算法及其改进算法达到收敛需要较多的迭代步数,而且非常容易产生振荡。本节将结合液压主动降脉特点,对 FLMS 学习算法及 B 样条神经网络学习算法进行仿真研究,以获取合理的 B 样条神经网络结构参数,为后续实验研究作准备。仿真软件采用 Matlab 语言编写。

### 10.5.2 主通道模型为线性模型的仿真结果

在基于 FLMS 算法的自适应有源噪声控制系统及自适应有源脉动控制系统仿真模

型中,一般假设系统的主通道模型  $H_{pe}(z)$  及误差通道模型  $H_{\varphi}(z)$  是线性的,而更一般地只假设其为一延迟环节<sup>[227]</sup>。所以,本节在系统主通道为线性模型的情况下,分别对 FLMS 算法及 B 样条神经网络算法进行仿真研究。假设系统各组件的模型如下:

原始脉动信号为

$$y = \sin(2\pi \times 10t) + 0.4\sin(2\pi \times 20t) \quad (10.29)$$

脉动主通道模型  $H_{pe}(z)$  为

$$y(k) = x(k) + x(k-1) \quad (10.30)$$

误差通道模型设定为伺服放大器与伺服阀的传递函数<sup>[241]</sup>,即

$$H_{\varphi}(s) = \frac{1.26 \times 10^{10}}{s^3 + 2.325 \times 10^3 s^2 + 2.07 \times 10^6 s + 1.57 \times 10^9} \quad (10.31)$$

仿真结果见图 10-8 所示。由图可看出,FLMS 算法的初始稳定性及收敛速度都不如 B 样条神经网络算法。




图 10-8 FLMS 算法与 B 样条神经网络算法的仿真结果比较

### 10.5.3 主通道模型为非线性模型的仿真结果

由于液压系统中的压力脉动特性受液压系统管道的结构布局、系统中各元件特性、系统的稳定工作压力、系统的工作状态及外界环境等因素的影响,系统中的压力脉动具有严重的非线性特性。因此,脉动主通道模型  $H_{pe}(z)$  确定为如下的非线性模型

$$y(k+1) = \frac{0.875y(k) + x(k)}{1 + y^2(k)} \quad (10.32)$$

原始脉动信号确定为一基频与二倍频脉动信号之和

$$y = \sin(2\pi \times 10t) + 0.4\sin(2\pi \times 20t) \quad (10.33)$$

由于脉动主通道的模型为非线性,在仿真中,FLMS 算法很容易发散,因此,下面只对 B 样条神经网络控制进行仿真研究。

图 10-9 及图 10-10 为在相同的输入区间划分数  $m$ 、不同的样条数  $k$  时的收敛过程。由图可看出,在输入区间划分数  $m$  相同时,增加样条数  $k$  可以提高收敛速度及控制效果,但过大的样条数  $k$  会造成相邻的接受域函数冲突加大,输出层权系数的调节个数




图 10-9 输入区间划分数  $m=8$ 、样条数  $k=4$  时的仿真结果




图 10-10 输入区间划分数  $m=8$ 、样条数  $k=6$  时的仿真结果




图 10-11 输入区间划分数  $m=7$ 、样条数  $k=5$  时的仿真结果



增加,反而得不到更好的收敛过程。而且由于算法的运算量增加,增加了实时控制的困难。仿真研究表明,样条数  $k$  一般取 3~6 就能满足有源脉动控制的要求。

图 10-11 与图 10-12 为在相同的样条数、不同的输入区间划分数时的收敛过程。由图可看出,随着输入区间划分数的增加,系统的收敛性能并没有得到改善。这是因为当划分数增加时,各划分区间落入的输入点相对减少,而训练的权值总数却增加了,结果造成系统的收敛性能变差。仿真研究表明,当样条数取 3~6、输入区间划分数取 4~8 时,基于神经网络的压力脉动主动控制系统能取得较好的效果。




图 10-12 输入区间划分数  $m=9$ 、样条数  $k=5$  时的仿真结果

## 10.6 试验研究

### 10.6.1 试验装置简介

神经网络自适应压力脉动主动控制系统试验原理框图,如图 10-13 所示,主要由主控计算机、初级脉动源、次级脉动源、误差传感器、隔直放大电路、伺服放大器、以及测量变

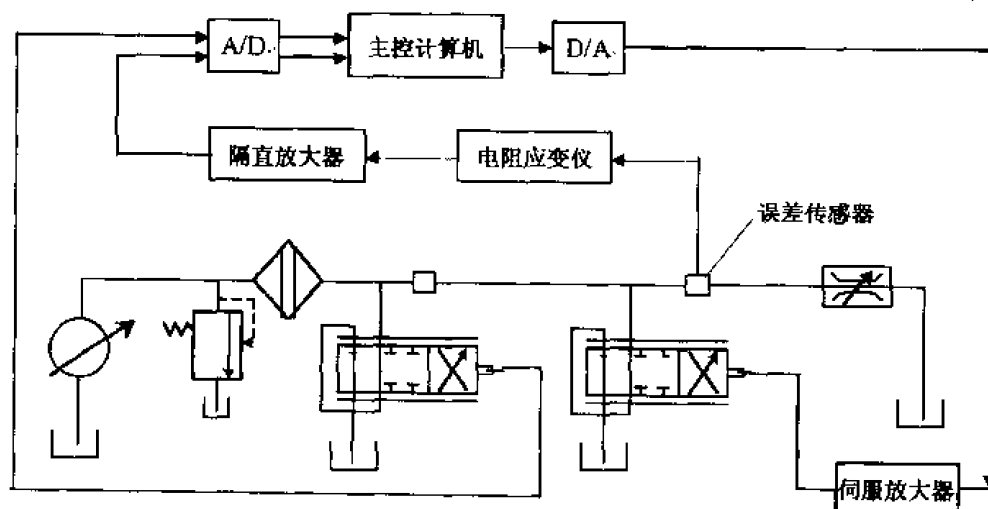


图 10-13 控制系统试验原理图

换电路等组成。

图中各元件的规格及作用如下:

初级脉动源。由 QDY - 32 型伺服阀来实现,用于产生原始压力脉动。脉动频率及大小由信号发生器的频率及大小所决定。在试验前需加入一定的直流分量,使伺服阀有一定的预开口量,预开口量应大于试验中的交流信号所引起的开口量,以使伺服阀能产生所需要的脉动流量。

次级脉动源。亦由 QDY - 32 型液压伺服阀来实现,用于产生次级压力脉动,脉动频率及大小由计算机的输出决定。同初级脉动源所用的伺服阀一样,次级脉动源所用的伺服阀也应在试验前给一定的预开口量,此开口量与控制系统的算法有关。当算法对初值较敏感时,开口量应取较大值;当算法对初值不太敏感时,取相对较小的值,以保证在控制开始阶段,控制系统对初级脉动有较大的衰减能力。

误差传感器。采用型号为 LPT - 15 型压力传感器。用于检测有源脉动控制系统衰减压力脉动的效果。在控制过程中,可用此信号来调整控制器的参数,使传感器所在位置的脉动达到最小。

隔直放大电路。在液压系统中,系统的工作压力通常很高,而压力脉动则相对较小。因此,压力传感器输出信号中不仅包含脉动信号,而且包含较大的直流信号。隔直放大电路的作用是将压力传感器输出信号中的直流成分滤掉并加以放大,以便进行压力脉动控制。该电路为自制电路。

超低频信号发生器。采用 BT6A 型超低频频率测试仪,用于给初级脉动源伺服阀发信号,包括正弦波、方波及三角波三种信号。

此外,自制的伺服放大器给伺服阀提供所需控制电流;自制的模拟滤波器用以滤去由液压泵引起的较高频率的脉动;多通道数据采集板采用 PC - 1232C(N)型 32 通道数据采集板;节流阀采用 LF - L20 型节流阀,用于调节液压系统的工作压力;电阻应变仪为 YD - 25 型电阻应变仪,用来测量误差传感器处的脉动信号;磁带记录仪采用 SONY 公司 instrumentation type recorder;安全阀为 YF - B32B 型溢流阀。控制系统的硬件实现环境为 Pentium100 型微型计算机。

### 10.6.2 试验结果及分析

FLMS 算法对初值比较敏感,且收敛速度很慢。此外,对含有严重非线性的液压自适应降脉系统来说,实现其算法需要辨识误差通道的模型,即次级脉动源至误差传感器的模型,而此模型受系统元件、系统工作压力的影响,有很强的时变性及非线性。试验中,我们采用两种方法,一是对其进行离线辨识,并利用辨识模型来实现 FLMS 算法,二是直接采用在线辨识来进行控制,但结果均未成功,控制系统一开始就很快发散。这表明采用一般自适应控制算法进行液压系统压力脉动主动控制是不合适的。

基于 B 样条神经网络的自适应控制算法属于直接自适应控制,不需要辨识误差通道的模型,而且 B 样条神经网络属于局部逼近神经网络,实时性及快速收敛性都得到了有效保证,我们采用初级脉动源分别为 20Hz、30Hz、40Hz、50Hz、60Hz 及 70Hz 的正弦波进行试验,均获得较好的结果。

下面以 50Hz 正弦波为例来加以说明。图 10 - 14 及图 10 - 15 给出了初级脉动源为

50Hz 的正弦波时,误差传感器处的压力脉动在控制前后的衰减情况。其他频率点的衰减情况如图 10-16 所示。




图 10-14 控制前、后压力脉动波形图




图 10-15 控制前、后压力脉动频谱图

此外,为了验证基于 B 样条神经网络的自适应有源脉动控制系统的有效性,我们还对初级信号为方波、三角波及其复合信号也进行了试验,均取得了同样的衰减效果。这说明了神经网络自适应主动降脉系统的开发是成功的,基于 B 样条神经网络的控制算法是可行而有效的。在整个试验过程中,B 样条神经网络参数的选择范围较宽,样条的次数在 3~5 之间就可满足要求。试验结果还表明,样条次数太多反而使收敛速度有些下降。输入区间的划分数只要比样条次数大 1~3 就可以满足要求。这些参数的数量少、选取简单,从而为算法的实时性及快速收敛提供了有效保证。




图 10-16 不同频率点的压力脉动衰减情况

## 10.7 本章小结

在液压系统的压力脉动中,既包括有中、高频脉动,又包括有低频脉动。对低频脉动,采用被动控制方法效果较差。为此,本章提出了采用主动方法对液压系统的低频脉动进行衰减。我们首先对液压系统有源脉动控制原理及衰减脉动机理进行了分析,然后针对液压有源脉动控制系统存在着严重的非线性及时变性,提出了基于 B 样条神经网络的液压系统压力脉动主动控制系统,并对其进行了仿真及试验研究,可以得出以下结论:

(1) 液压系统的压力脉动存在严重的非线性及时变性,因而基于 FLMS 算法的液压有源自适应脉动控制系统的控制效果很差。

(2) 提出的基于 B 样条神经网络的压力脉动主动控制算法实时运算量不大,非常适宜于实时控制。而且 B 样条神经网络属于局部逼近神经网络,初值稳定性及收敛速度均明显优于 FLMS 算法,特别适合于非线性较为严重的系统控制。

(3) 设计并开发的基于 B 样条神经网络的液压系统压力脉动主动控制系统基本满足了液压有源降脉技术研究的试验要求。当初级信号为正弦波、三角波、方波及其复合信号时,该系统均取得了衰减压力脉动 8.5~11.6dB 的效果。同时也证明了该系统的有效性 & 神经网络算法的正确性。

## 第十一章 大型智能电液伺服结构试验系统

### 11.1 工程背景

结构试验系统是用于结构静力加载和疲劳加载试验的机-电-液一体化负载模拟试验系统,主要用于大型结构和工业设备的动、静强度和动态特性的实验研究。它通过模拟被试对象在实际环境中的工作状态,使其预先暴露缺陷,达到了解其力学性能的目的,以便为产品改进和新产品研制提供依据。对于几何形状、工作条件复杂的机械结构,结构试验是确定其静、动力学特性的惟一方便而有效的方法。对较简单的机械结构,它不仅能验证理论分析结果的正确性,还可确定结构在一定载荷作用下的应力分布、承载能力和稳定性,从而合理评价结构的完整性、耐用性和适应性<sup>[89]</sup>。

在工程实践中,结构试验是提高产品质量和使用可靠性的根本保证。它在理论设计与实际对象之间架起了沟通的桥梁,是缩小二者差距的有效手段。随着工业技术特别是航空、航天及汽车等工业的发展,结构试验研究日益受到人们的重视<sup>[117~119]</sup>。目前,结构试验技术已遍及工农业生产甚至日常生活的各个领域。它既是一门分散型技术,又是一门知识密集型技术。涉及的知识面宽,交叉学科多,应用领域广。随着相关技术的发展,结构试验理论、方法和应用研究均日趋完善,并逐步形成一门独立的学科。在工程实践中发挥出越来越大的作用。

然而,长期以来,我国的科学与技术研究偏重于机制、原理和方法的研究,而相对忽视了真实工程结构的设计理论和设计规范等基础性研究,理论和试验之间存在着相当大的差距。为了弥补不足,缩小我国理论研究和试验验证之间的差距,使我国的结构试验与测试技术上上一个台阶,努力缩小与国外先进试验技术和试验规模之间的差距,促进我国民族工业的发展,1992年国家教委组织有关专家,通过研究论证,决定在西安交通大学率先建设一套技术先进、性能优良的结构试验装置,以便对矿山机械、汽车、动力机械、管道容器、电气设备及其他大型装备部件或拼装结构进行动、静强度和动态特性的高水平的实验研究。

本章的工作就是在这一背景下进行的。

本章首先介绍了大型结构试验系统的概况及其发展情况,然后针对结构试验系统的特点及要求,研制了神经网络智能伺服加载控制系统和数据采集与分析系统<sup>[242~245]</sup>,介绍了系统的硬、软件设计,并通过实验证明了控制系统的良好性能。最后作为应用实例,采用电液位移伺服加载系统,对某厂研制生产的 SX6122 型大型客车三类底盘与 WD61561 型发动机的匹配性能进行了摸底试验。实验和应用结果均表明,神经网络智能伺服加载控制系统控制品质优良,能较好地处理被控对象的非线性和时变不确定性;载荷谱设置方便,可满足各种试验规范的需要。

## 11.2 大型结构试验系统概述

由于电液伺服系统具有出力大、响应快、精度高的优点,与计算机连接可进行各种复杂的控制和数据处理,因此结构试验系统多采用电液伺服控制系统。它主要由控制器、电液伺服阀、液压缸、检测元件和液压油源系统等组成,其工作原理如图 11-1 所示。

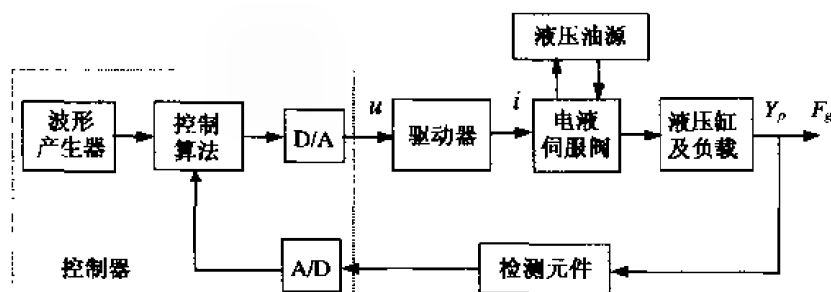


图 11-1 电液伺服结构试验系统原理图

控制器是结构试验系统的核心,用来产生各种试验波形,并完成信号的处理,实现控制算法。

电液伺服阀是将控制输入的电流信号转换为液压能的元件。它是电液伺服控制系统中的关键元件,其性能对整个系统的控制品质影响很大,其节流特性会引起液压系统的非线性。

液压缸接受电液伺服阀输出的压力油,使活塞按给定信号的要求进行往复运动。被试件一般装在活塞杆的末端,由液压缸的高压液压油通过活塞杆对试件施加作用。液压缸也是电液伺服控制系统中的一个重要元件,其内部泄漏会造成系统的工作状态发生改变。

检测元件包括传感器及其调节电路,用来检测被控量的大小。根据被控量的不同,传感器可有位移传感器、力传感器和加速度传感器等。

由图 11-1 可见,电液伺服结构试验系统在工作过程中,首先由控制器产生被试对象所需要的各种载荷波形,如正弦、方波、三角波、随机波及各种组合波形等,并转换成相应的电压信号,同时接受由传感器检测到的位移、力或加速度经转换处理后的电压信号,二者进行比较,并通过控制算法处理,产生系统的控制输入;然后通过驱动电路将控制输入电压信号转换为电流信号,送到电液伺服阀,使其输出相应的流量(流量阀)或压力(压力阀),控制液压缸使活塞带动试件按给定的输入波形运动,从而按试验要求实现对试件的加载。

控制过程中,液压油源系统通过伺服阀不断地向液压缸提供压力油,使其带动负载按给定信号运动。

结构试验系统的控制方式通常有力伺服加载和位移伺服加载两种方式。假定系统负载为质量、弹性和阻尼,则其经典的动态模型可用(3.29)~(3.31)式来描述。这是一单输入多输出非线性系统(工程实践中通常采用多点加载方式,因此实际系统可视为多输入多输出系统),除了电液伺服系统的一些特点外,还有其自身的许多特点。具体表现在以下

方面:

① 非线性:非线性是电液伺服系统中普遍存在且至今没有得到很好解决的难题,它主要是由电液转换与控制元件的节流特性和液压动力机构的滞环、死区、游隙及限幅等因素引起的<sup>[108]</sup>。此外,在加载过程中,当被试结构产生塑性变形或遭受破坏时,亦会产生严重的非线性。

② 时变性:参数时变是电液伺服系统的一大特点。这是由于液压缸的内部泄漏、液压油的可压缩性及外部干扰等因素的影响,造成系统的一些参数如  $\beta_e$ 、 $c_f$  等随着工作状态的改变会产生大范围变化。另外,在加载过程中,当载荷或位移超过一定范围时,被试件将产生塑性变形,其参数也将随载荷的变化而变化。

③ 不确定性:根据试验目的和要求的不同,结构试验系统要完成的任务不同,系统特性存在着很大差别。即使对同一类试验,由于试件千差万别,试件的材料、形状、结构和加载点的位置又千变万化,加载过程中结构的弹塑性变形亦各不相同,这些均造成系统参数可在大范围内改变。

④ 未知性:大型结构试验系统是一个多通道加载系统,各通道对加载对象所产生的结构变形会造成多通道间的严重耦合,且这种耦合关系难以定量描述和测定。另外,在试验中,随着加载进程的发展,试件会产生疲劳破坏或断裂破坏,加载进程信息是不确定的。对控制系统而言,这些因素造成系统的信息存在未知性和不完全性。

可见,这类系统工作范围宽,时变参量多,负载扰动大,是一类典型的未知不确定非线性系统,难以精确建模,给工程控制带来了诸多困难。

根据试验对象和试验目的的不同,电液伺服结构试验系统的功能可分为以下三种:振动波形再现、疲劳加载试验以及静力与协调加载试验等。

### 1. 振动波形再现

此时,结构试验系统相当于电液振动台系统,因其可产生较大的输出力,功率重量比高,常用来进行地震波的模拟,实现振动波形再现。可广泛地用于工程结构的抗震性能研究。此外,还可用来进行结构动力学试验,以验证复杂工程结构理论计算模型的正确性,并用试验结果去修正理论计算模型。

对振动台系统而言,负载比较简单,通常是质量负载。试验时,将被试件固定在振动台上,使试件随台面一起振动,从而把运动传递给试件。控制量主要是加速度。但一般来说,结构试验系统控制的是位移,加速度可由位移量经二次微分后得到。

### 2. 疲劳加载试验

疲劳加载试验主要用于结构或材料的疲劳寿命及裂纹扩展规律等动态特性的研究。

通常,工程实践中的很多结构和机械部件在工作时不仅要承受静应力的作用,而且还会受到复杂的交变应力的作用,此应力可能超过材料的屈服强度,且加载频率低,甚至每一循环都会产生一定量的塑性变形,从而导致结构的累积损伤而遭破坏。因而低周疲劳试验对于研究机械结构的疲劳寿命、裂纹的扩展等具有十分重要的意义<sup>[246]</sup>。

一些国内外学者在研究结构裂纹的萌生、扩展、断裂的过程时发现,加载方式对疲劳寿命产生的影响很大。Kerjo Tokaji 研究发现,用二级水平载荷方式加载对疲劳裂纹的增

长特性有很大的加速作用。Jan Zuidema 的研究成果表明,块欠加载方式与块过载加载方式相比,少量的欠加载导致裂纹扩展的加速,而大量的欠加载则导致裂纹的滞阻现象。M. Nakagaki 发现,加载方式不同不仅会引起裂纹扩展的加速和滞阻情况不同,同时也会引起裂纹表面的变形不同,而且当载荷去除后,裂纹的闭合方式也不同。这些研究启发我们,在实验室里再现这些复杂的载荷波形对研究机械结构的疲劳特性有重要意义。通过试验,建立理论分析与实际情况之间的联系,从而给出可信的结论。

在疲劳加载试验中,负载通常是质量+弹性负载,特性复杂,非线性比较严重。控制量可以是力,也可以是位移或变形。对柔性结构,一般采用位移伺服加载,这时控制量是位移或变形,力载荷只能监测而不能控制;对刚性强的结构,通常采用力伺服加载,这时系统是一种力控制系统。

### 3. 静力与协调加载试验

静力与协调加载试验主要用于研究结构的静强度和静力分布情况,以及在一定载荷作用下,结构的承载能力和稳定性问题。控制量主要是力,这时试验系统是一种力伺服控制加载系统。

## 11.3 电液伺服结构试验系统的研究现状与发展要求

众所周知,工业生产中各种材料、零部件、构件以至整机或整个建筑物都需要经过试验才能确定它们的力学性能。在了解了这些性能之后才能使设计更加合理、使用可靠。也只有经过试验,才能确定产品性能的优劣。因此,试验机在国民经济发展中占有相当重要的地位,它的发展水平在某种程度上反映了一个国家的工业发展水平。因而世界各国都很重视结构试验技术和试验系统的研究工作<sup>[246~251]</sup>。

目前,国内外开展结构试验研究的设备大多采用美国 MTS 公司、英国 Instron 公司、瑞士的 Amstler 公司、德国的 Schenck 公司和日本鹭宫株式会社的产品。这些产品主要是采用 PID 控制器控制加载试验的。控制系统结构简单,控制可靠,速度快,鲁棒性强,较好地满足了结构试验系统快速性和可靠性的要求,为新型结构研制和产品试验发挥了重要作用。从整体性能看,技术处于领先水平的当数 MTS 公司的产品,可实现多种试验波形(包括组合波形)的加载试验,硬件集成度高,体积小。但由于控制方法仍采用传统的 PID 组合方法,其缺点是控制参数的选取较强地依赖于系统的模型,适应性差。对不同的试验对象,参数设置与操作者的经验有关,调试相当麻烦。同一对象在不同的试验阶段,参数调整就更加困难,在工程试验中有时甚至是不允许的。控制效果受到系统特性变化和其他不确定因素的影响很大,精度一般较差,疲劳加载精度通常在 10% 左右。对耦合严重的结构,多通道加载试验常常无法保证控制精度。

进入 90 年代以来,国内也加强了结构试验系统的研究工作。并将自适应控制引入结构试验系统中<sup>[113]</sup>,出现了自适应同步加载系统<sup>[249]</sup>和多通道协调加载系统<sup>[119,251]</sup>,在一定程度上提高了系统的适应能力和控制精度,如静力同步加载精度可达 0.5%。但功能单一,仅适用于小位移的结构静力或协调加载试验。对具有大位移、大变形的结构试验,尚不能保证控制精度;对时变不确定非线性系统,仍有很大的局限性。难以满足日益发展



的各种试验规范的需要。

另外,在试验过程中,上述产品均未实现试验控制和测试分析一体化,不能做到试验数据的实时采集与处理。

实际工程结构大都工作在复杂环境中,不仅存在静力作用,还面临疲劳破坏,其自身特性和工作状态均千差万别。此外,结构在试验过程中会产生塑性变形,刚度突变,且结构的弹塑性变形会造成多通道间的耦合干扰,使系统具有严重不确定性。要满足各种不同试验对象和试验规范的需要,并有效处理结构试验中不确定非线性因素的影响,确保试验精度,结构试验系统必须朝智能化方向发展。

为此,对结构加载控制系统设计提出了如下要求:

① 在满足稳态精度的前提下,应具有良好的动态特性,能实现快速、平稳、高精度、无超调的控制目标。

② 应具有较强的智能,能学习并适应系统的未知特性,并能有效处理系统参数变化、外负载干扰和交叉耦合干扰以及非线性因素引起的不确定性问题。

③ 能实现控制和测试分析一体化,以便在试验过程中,做到试验数据的实时采集与处理。

④ 应具备完善的保护功能,且操作简单,使用方便。

## 11.4 大型智能电液伺服结构试验系统设计

考虑结构试验系统是一多输入多输出时变非线性系统,并具有严重不确定性<sup>[89,136]</sup>,传统的基于模型的设计方法已难以奏效。因此,为克服传统 PID 和自适应控制方法的局限性,确保试验精度,确定大型智能结构试验系统的研制思路是:采用现代控制手段和方法,解决结构试验中的复杂非线性、时变不确定性等控制问题;利用软、硬件结合的互补优势,实现对结构疲劳加载和静力与协调加载的平稳、快速、高精度控制;同时考虑试验需要,采用多机并行工作方式,实现试验控制与测试分析一体化,做到试验数据的实时采集与处理。为此,研究的智能结构试验系统采用多通道阀控缸系统,它主要有三个部分组成,包括电液执行机构系统、智能伺服加载控制系统和计算机实时数据采集与分析系统等,如图 11-2 所示。

结构试验系统工作时,由控制系统根据试验谱要求,提供适当的控制信号,驱动电液执行机构对试件进行力或位移加载。数据采集与分析系统与控制系统采用多机并行工作方式,根据需要进行试验数据的实时采集与处理,协助控制系统完成试验任务。

### 11.4.1 神经网络智能伺服加载控制系统

#### 1. 系统组成及硬件设计

神经网络智能伺服加载控制系统是大型智能结构试验系统的核心,主要用于大型工业结构的疲劳加载控制和静力与协调加载控制,如图 11-3 所示。

该系统主要由神经网络智能控制器、试验波形产生器、变增益信号处理器、数模混合智能驱动器、遥控系统、保护系统等组成。系统的工作原理如图 11-2 所示,控制器根据

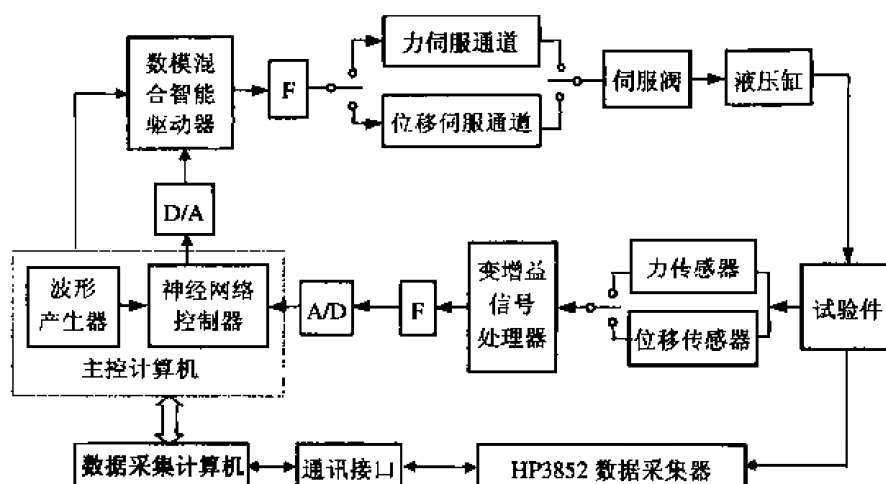


图 11-2 大型智能结构试验系统原理图



图 11-3 神经网络智能伺服加载控制系统

试验规范的要求,产生各种试验波形,并转化成电压信号,同时接受传感器检测到的实际力或位移加载信号经处理转化后的电压信号,二者进行比较,并通过神经网络控制算法在线校正控制量,驱动伺服阀,带动液压缸按指定方向运动,从而按试验规范的要求实现力或位移载荷的静态与动态加载控制。

系统可提供的控制方式有点跟踪、有效值、平均值和最大值控制法。

#### (1) 控制器设计

由于结构试验对加载控制性能要求较高,载荷调节要快速、平稳,无超调,稳态精度要高。常规PID控制方法除了参数整定工作量大以外,控制效果也难以满足要求。为此,采用神经网络智能控制方法,以期利用神经网络的学习能力和非线性映射能力,解决结构

试验系统中的复杂非线性、以及时变、耦合带来的不确定性等问题,从而提高试验精度。基本控制思想是:将多通道加载系统分为多个单缸加载系统,并将通道间的耦合及参数时变带来的影响视为各单缸加载系统输出端的一种扰动,然后对每个单缸系统采用神经网络控制策略进行控制。控制参数的调整采用第六章提出的神经网络在线自学习模糊自适应控制算法来实现。实践证明,神经网络控制方法对每个单缸系统均具有良好的控制精度。

神经网络控制器和试验波形产生器由主控计算机 NEC433 来实现。A/D、D/A 均采用 16 位 AX5621 高速板。为保证系统的工作时序和回路时间,A/D、D/A 采用中断方式工作。系统中 A/D、D/A 滤波器均采用 8 阶 Bottworth 滤波器,用于信号的防混淆滤波和平滑滤波,避免控制初期液压系统可能产生的颤振。

### (2) 试验波形的产生

试验波形由计算机软件产生,利用软件的灵活性可产生和存储几乎所有的经典加载波形:正弦、三角、锯齿、梯形、方波及雨流随机波等。另外,通过连接不同的加载程序块,可以得到上述加载块的任意组合波形,可广泛满足不同试验对象的试验需要。

组合波形产生的思想是:规定一个单一加载程序块中只含有一种频率和一种幅值的波形,进行组合时,只需设置组合块中波形的类型(正弦波、三角波等)、频率、幅值和加载次数即可。

### (3) 变增益信号处理器

系统的输出响应信号要经力或位移传感器转换为电信号,并通过反馈回路传送至控制器进行控制运算。要求反馈回路具有输入阻抗高,漂移小,噪声低等特点。另外,由于试验对象和加载量的不同,现场测量信号也千差万别,有些可直接采集,有些需经适当处理才能转换为能采信号。为此研制了输入阻抗高、漂移小、噪声低的可变增益信号处理器,其增益可在 1~1000 倍范围变化。对不同灵敏度的传感器和不同的加载量,均能充分利用 A/D 的最大位数,有利于改善信噪比,提高控制精度。

### (4) 数模混合智能驱动器

对不同的加载对象和加载过程的不同阶段,控制输出量的要求也不同。因此,控制器输出接口设计了两级串行数模混合智能驱动器。其作用有二:一是给加载通道增加一模拟反馈回路,目的是在神经网络智能控制系统启动前,使加载系统建立一个稳定的初态,以克服伺服阀可能存在的非零开口对系统稳定性的影响;二是与神经网络控制算法一起,根据系统的跟踪误差和加载进程的需要,实时调整回路增益,实现高精度的神经网络智能控制策略。

### (5) 多机通信接口

在试验过程中,为了完成试验数据的实时采集与分析工作,智能加载控制系统采用了多机并行工作方式。其中主控计算机主要用于试验系统的加载控制操作,并担负数据采集系统的启动工作;数据采集计算机主要完成试验数据的实时采集与处理。两台计算机间的通信通过 8255 接口进行。

### (6) 遥控系统

为方便液压油源的操作和调节,研制了油源远距离遥控装置,可在控制室对油源进行启动、压力调节、流量调节、卸荷、关机等操作,并能对油温和压力进行监控。

### (7) 保护系统

为保证试验系统能可靠、安全地工作,避免损坏实验件或人生事故等,控制系统设置如下保护功能:

① 误差超限保护:当系统输出的直流误差信号超过允许的限量值时,控制系统将自动终止实验,并关闭油源。

② 输出反馈超限保护:在试验过程中,当输出响应超过预先设置的允许上、下限值时,控制系统自动终止实验,并关闭油源。

③ 夭折保护:当系统不能按期望的特性再现试验波形时,控制系统提供夭折功能,可由操作人员手动中止试验。

④ 紧急关机保护:当试验系统或试验件出现异常情况时,控制系统提供紧急关机保护,由操作人员手动紧急关机,并切断油源。紧急关机保护可遥控操作,也可现场操作。

## 2. 软件设计

控制系统软件设计要求可靠性高、占用内存小、执行速度快、人机界面良好。针对电液伺服系统的特点和要求,控制系统软件采用 QUICKC 语言设计、编写,主要由参数设置、控制和图形输出等三个模块组成。软件总体结构如图 11-4 所示。




图 11-4 控制系统软件总体结构

### (1) 参数设置模块

参数设置模块完成各种试验参数的设置与装订,做好试验前的数据和硬件准备。主要功能有:

① 设置试验名称、试验日期和试验开始时间。

② 设置各种控制参数,如控制误差限、修正因子,选择控制方式、采样通道、采样平均次数、延迟步数,设置传感器类型及灵敏度等。通过设置,可根据不同的试验对象和要求,灵活地组织试验。

③ 设置试验标准。根据载荷谱的要求,定义加载波形、频率、幅值和相位,以及启停加载时间等。

④ 检查各通道的受力情况和各加载点的状态,确定静态直流偏置,完成系统标定和调零。

⑤ 试验前检查。检查通道分配、试验标准设置和各类试验参数设置是否正确,并存储试验参数文件,确保试验正常进行。

⑥ 装订或打印试验参数文件。

⑦ 控制系统诊断。对控制系统硬件设备进行诊断,如 A/D 诊断、通道完整性诊断、输入/输出诊断、与数采系统的通讯诊断等,确保试验过程中,硬件设备工作正常。

## (2) 控制模块

控制模块是控制系统软件的核心,流程如图 11-5 所示。用来控制试验过程,完成系统的疲劳加载控制和协调加载控制,主要功能有:

- ① 检查系统各项输入参数,完成试验初始化。
- ② 根据试验标准,产生试验波形,并进行误差检测,运行控制算法,实现对各通道疲劳加载或静力与协调加载、卸载的控制。
- ③ 实时显示各种控制曲线及试验状态。
- ④ 根据试验状态或要求,发送数据采集命令,控制数采系统采集数据,并处理数采系统回送的信息。
- ⑤ 根据试验进行情况或要求,进行数据存储和格式转换、打印各类数据报告等。
- ⑥ 处理加载过程中发生的各种系统故障。

## (3) 图形输出模块

图形输出模块完成控制结果的处理,主要功能有:

- ① 进行各通道控制曲线、误差曲线的显示、测量与打印。
- ② 利用图像移屏技术,可显示、观察不同时间段的加载控制情况。
- ③ 产生并输出试验结果处理后形成的数据文件或图形文件等。

该软件设计具有以下特点:

- ① 软件按模块化设计思想,采用三级中文下拉式菜单结构,界面美观,层次清晰,交互性能好。试验标准设置、参数装订、通道选择等均通过键盘输入方式进行,不仅方便操作和学习,而且便于参数修改和功能扩展。
- ② 人机界面采用图、文、声联合显示方式,系统的监控状态清晰、直观。除了对系统工作实施干预的控制操作菜单和窗口外,监控软件还可通过不同方式显示系统的控制状态,有单通道监控画面、多通道、多参量监控画面等。此外,监控软件还可根据需要,实施状态记录、数据存盘和图形输出打印等功能。

### 11.4.2 数据采集与分析系统

#### 1. 系统组成及工作原理

在结构的静力加载和协调加载过程中,通常需要采集不同载荷下的应力、应变数据,以便分析结构的静、动力学特性。为此,我们利用计算机通讯技术,在多通道应变采集仪 HP 3852 的基础上,研究开发了结构试验系统的数据采集与分析系统,如图 11-3 右侧所示。其作用是在结构试验过程中,完成试验件试验数据的实时采集与分析处理。

数据采集与分析系统主要由主控计算机、数据采集计算机、多通道应变采集仪 HP3852、8255 并行接口卡和 IEEE-488 标准接口卡等组成。其工作原理如图 11-6 所示。

主控计算机主要用来完成对结构试验系统的加载控制;数据采集计算机用于试验数据的采集及处理,属从控计算机,由 CIC386/66 来实现。主、从控计算机间通过并行接口卡 8255 进行通讯。

在试验过程中,主控计算机根据静力加载试验的需要,给从控计算机发数据采集命

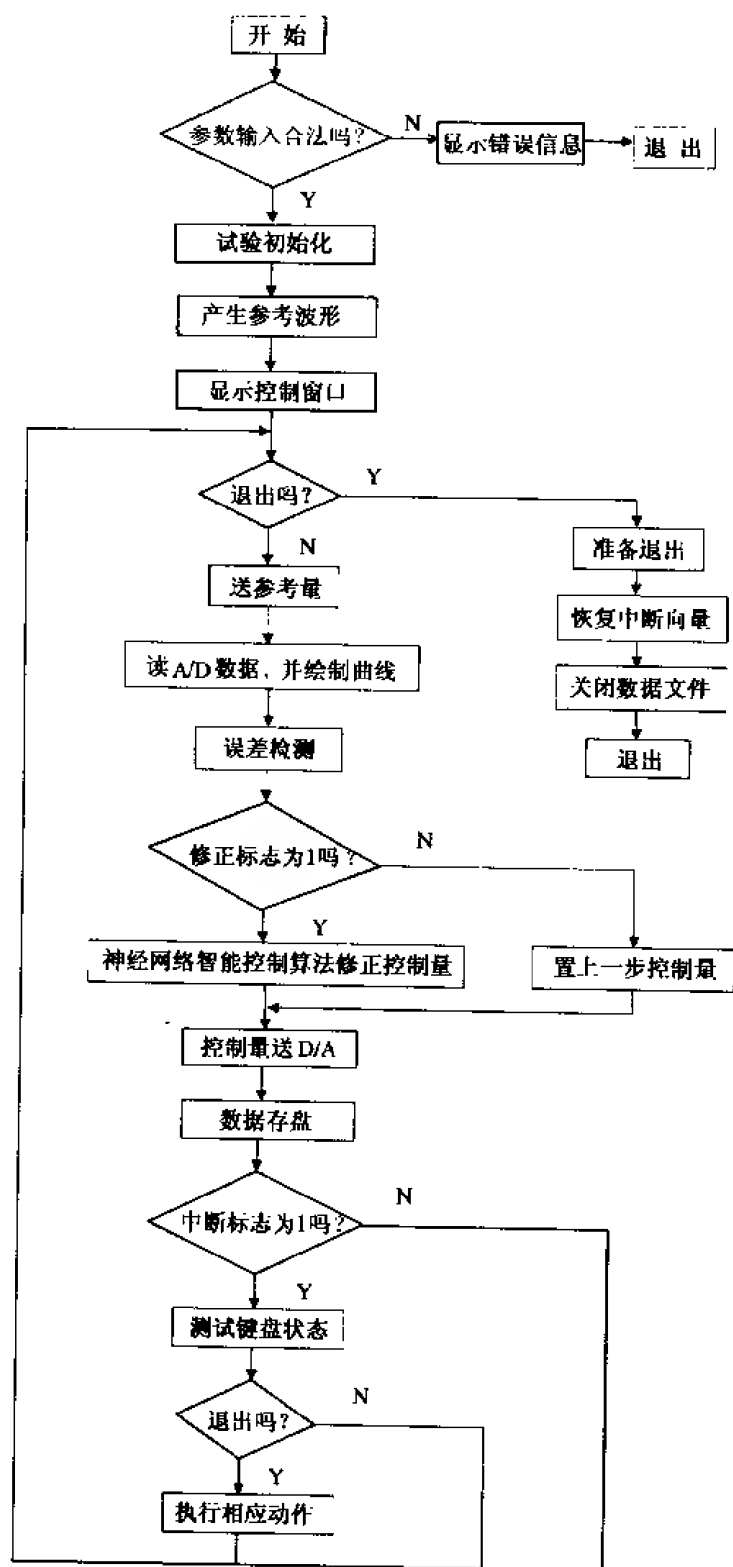


图 11-5 控制流程图

令。从控计算机一直处于等待状态,当接收到主控计算机发来的数据采集命令后,便通过 IEEE-488 标准接口卡驱动多通道应变采集仪 HP3852 采集试验数据。数据采集完毕




图 11-6 数据采集与分析系统原理框图

后,从控计算机给主控计算机返回“数据采集完毕”信号,并恢复到等待状态,同时可进行数据处理。主控计算机收到数据采集完毕信号后,方可继续进行加载试验或卸载操作。

## 2. 软件设计

数据采集与分析处理软件是计算机数据采集与分析系统的核心组成部分。考虑系统不仅要求有较高的数据采集和处理速度,而且要有良好的人机界面,因此软件设计采用结构化设计思想,通过中文下拉式和弹出式联合菜单形式来实现各种功能,如参数设置、数据采集、数据处理、数据打印等,结构清晰,操作简单,维护方便。软件编制采用 QUICK C 和汇编语言混合编程。数据采集及传送部分要求速度快,采用汇编语言编写;而人机对话及数据输入、输出部分则采用图形支持功能强的 QUICK C 语言编写。

数据采集和处理软件总体结构如图 11-7 所示,主要包括参数设置、数据采集和数据处理三个模块等。




图 11-7 数据采集和处理系统软件结构图

### (1) 参数设置模块

参数设置模块完成数据采集与处理的准备工作,主要包括下述内容:

- ① 设置试验名称、日期和试验开始时间。
- ② 确定结构的材料常数,如泊松比、弹性模量、屈服强度等。
- ② 确定数据采集通道数,设置各通道所使用的测量电桥。

### (2) 数据采集模块

数据采集模块是数据采集和处理系统软件的核心组成部分,它通过由数据采集计算机控制的数据采集单元 HP3852 来实时完成试验数据的转换、传输与采集,其工作流程如图 11-8 所示。

### (3) 数据处理模块

数据处理模块主要完成数据处理和图形输出两个功能。数据处理是对试验数据进行正态检测,以消除粗大误差、系统误差和随机误差等,数据处理方式有线性拟合和二次样

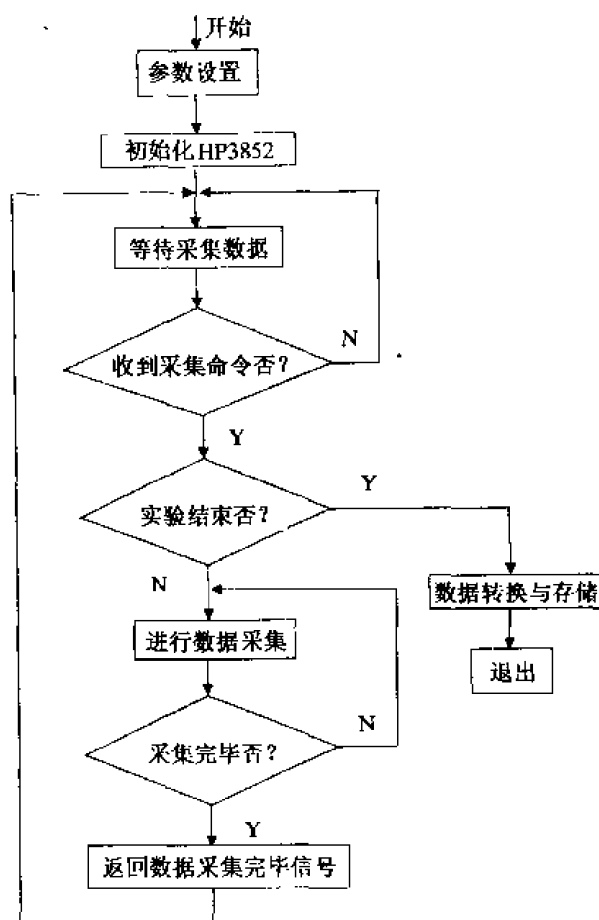


图 11-8 数据采集程序流程图

条拟合两种方式。处理结果可通过计算机屏幕,以图形或数据方式进行实时显示和输出。图形输出包括图形显示、光标测量、图形打印和拟合数据文件打印等功能。

计算机数据采集与分析系统与智能伺服加载控制系统配套使用,运行硬件环境为 C11386/66。该系统具有如下特点:

① 将传统的仪器面板操作转化为简单的图形界面菜单操作方式,实现了结构静力加载与协调加载试验中数据采集与分析处理的自动化,并具有各种实时监测功能,不仅提高了试验数据的采集速度和精度,而且可监测结构试验中各参数变化的瞬态过程。

② 可对采集的数据进行实时处理、显示和输出,也可将测试数据存盘保留,以便进一步分析和处理,操作灵活,使用方便。

### 11.4.3 电液执行机构

电液执行机构是结构试验装置中的施力机构,由液压油源系统、电液伺服阀、液压缸和承力机构组成。各主要元件的规格如下:

#### 1. 液压油源系统

液压油源系统由液压泵站、油路系统和其他附属装置等组成,如图 11-9 所示。油源



系统主要为液压缸提供所需要的压力油。系统的额定工作压力为 21.0MPa,由三台定量泵供油,每台泵的额定流量为 100L/min,它们可以独立工作,也可以联动工作。




图 11-9 液压油源装置

## 2. 电液伺服阀

电液伺服阀型号为 MOOGJ072-102;额定流量为 152L/min.;工作压力范围为 1.4~21.0MPa;频宽约为 30Hz。

## 3. 液压缸

液压缸为国产航空油缸,额定压力为 21.0MPa;最大静载荷分别为 200kN 和 100kN,最大动载分别为 170kN 和 80kN;最大行程均为  $\pm 100\text{mm}$ ;最大运行速度为 0.5m/s;频率范围为 0~25Hz。

与液压缸配套的检测元件有载荷传感器和直线位移传感器两种。直线位移传感器的额定测量范围为  $-100\text{mm} \sim +100\text{mm}$ ;载荷传感器的额定测量范围分别为 0~200kN 和 0~100kN。

## 4. 承力机构

承力机构由反力墙、承力地板和承力架三部分及其附属组件等组成。

其中反力墙高 6m,宽 10m,厚 2m。可承受最大剪力 2000kN,最大弯矩 12000kN/m;顶角变形  $\Delta h \leq 1/800$ 。承力地板长 13m,宽 10m,槽深 1.5m。最大承载能力为 6000kN,垂直向载荷为  $60\text{kN/m}^2$ ,槽道抗拔力为 300kN/m。

整个加载系统可根据需要进行拆装,通过配换不同的液压缸和承力机构,可实现对各类工业结构进行各种动、静载荷的加载试验。

#### 11.4.4 主要技术指标

##### 1. 协调加载控制

稳态精度:  $\leq 0.5\%$

动态精度:  $\leq \pm 1\%$

最大协调误差:  $\leq 2\%$

最大静载: 200kN; 最大动载: 170kN

##### 2. 疲劳加载控制

最大位移:  $\pm 100\text{mm}$

控制精度:  $\leq \pm 3\%$

系统频宽: 20Hz

加载波形: 正弦、半正弦、三角波、梯形波、方波、随机波、组合波形等。

### 11.5 实验研究

#### 11.5.1 静力与协调加载试验

##### 1. 单通道静力加载控制

加载对象是一两端固支的板块结构, 试验装置图如图 11-10 所示。图 11-11 给出了输出载荷为 15kN 时的加载控制曲线及其跟踪误差。

可以看出, 在初始控制阶段, 神经网络的学习不够完善, 跟踪误差较大; 经过有效次学习后, 控制器能较好地跟踪系统的特性, 对系统实施高精度的控制。动态误差在  $\pm 1\%$  以内, 稳态误差可控制在  $\pm 0.5\%$  以内。




图 11-10 单通道加载试验装置图




图 11-11 基于 NNOLFAC 的静力加载曲线及跟踪误差

为了比较神经网络在线自学习模糊自适应控制方法与单纯模糊控制方法及基于直接反馈误差学习的控制方法的优劣,我们在同一试验装置上,对后两种方法进行了试验研究。图 11-12 给出了单纯模糊控制系统进行静力加载试验的控制曲线。图 11-13 是基于直接反馈误差学习方法的加载控制结果。




图 11-12 基于模糊控制的静力加载曲线及跟踪误差

比较图 11-11 与图 11-12 及图 11-13,可以看出,在基于 NNOLFAC 的方法中,由于神经网络控制器 NNC 采用了模糊推理机产生的分目标学习误差进行训练,控制过程较其他两种方法更加平稳,尤其是启动过程较反馈误差学习法有很大改善,初始跟踪误差明显降低;同时,由于神经网络的精细学习能力,可做到对系统逆动态的高精度逼近,因而稳态加载精度比模糊控制结果要好。




图 11-13 基于直接反馈误差学习法的静力加载曲线及跟踪误差

## 2. 多缸协调加载控制

为检验控制系统的协调加载能力,图 11-14 给出了输出载荷分别为 20kN 和 15kN 的两通道协调加载控制误差曲线。可以看出,控制器对多缸的协调加载具有良好的控制能力,协调误差远小于设计任务书规定的 2% 的要求。




图 11-14 两通道协调加载控制误差曲线

## 11.5.2 疲劳加载试验

### 1. 单缸疲劳加载控制

试验装置如图 11-6 所示。图 11-15 给出了正弦波低周疲劳加载控制曲线。可以看出,控制器能平滑地跟踪学习系统的特性,并对其实施良好的控制。在初始阶段,NNC 的学习不够完善,响应是一渐近自适应收敛过程,经过有限次在线学习后,系统可得到有效的控制,没有出现超调和振荡,动态精度可达 1% 以内。

图 11-16(a~d)分别给出了方波、锯齿波及部分组合块低周疲劳加载控制曲线。




图 11-15 正弦波疲劳加载控制曲线




图 11-16(a) 方波疲劳加载控制曲线




图 11-16(b) 锯齿波疲劳加载控制曲线




图 11-16(c) 正弦-锯齿波组合块疲劳加载控制曲线




图 11-16(d) 正弦-三角波组合块疲劳加载控制曲线

## 2. 多缸同步加载控制

通道 1 试验装置如图 11-6 所示;通道 2 试验装置如图 4-8 所示,加载对象为汽车板簧-小车系统,板簧刚度未知,且呈不确定非线性变化,相当于给系统引入一个不确定干扰。

图 11-17 给出了两通道正弦波同步加载控制结果。可以看出,神经网络控制器能平滑地学习系统的逆动态特性,经过有限次在线训练后,可对系统实施良好的控制,未出现超调和振荡,并对板簧引入的不确定性具有良好的适应能力。这一结果与第四章提出的神经网络并行自学习鲁棒自适应跟踪控制的结果类似,但由于采用了模糊推理学习方法,收敛过程更加平稳,但收敛时间稍长。




图 11-17 两通道同步加载控制结果

## 11.6 应用实例

### 11.6.1 试验对象及要求

试验对象为某厂研制生产的 SX6122 型大型客车三类底盘。目的是对该底盘与 WD61561 型发动机的匹配性能进行摸底试验。要求对该底盘进行弯扭结合加载试验,摸清交变载荷工况下底盘的交变应力分布,以便为产品改进提供依据。

传统的试验方法是利用汽车试验场进行的。为了满足各种汽车在不同使用条件下的试验要求,需要在试验场中建设具有各种断面的特种试验道路,如正弦曲线断面的斜波浪形、矩形断面的斜凸起形等等,这就要求有足够大的试验场地和相应的设施。当试验条件改变时需要重新修建试验道路,因而给制定试验方案带来很大的局限性,同时加长了试验

周期,增加了试验费用。

目前,随着结构试验技术的发展,加载试验已成为检查汽车等产品的动力学性能、评价其经济性与稳定性的主要手段。为此,我们利用研制的大型智能电液伺服结构试验系统来完成此项试验。

### 11.6.2 加载及测试系统设计

根据试验需要,底盘试验采用对角固支、对角设液压缸的加载方案。左侧后轮与右侧前轮处为固定支撑,左侧前轮与右侧后轮处设液压缸。两缸进行同向加载,使底盘承受弯、扭联合的受力状态,以模拟汽车在行进中,一轮或不同侧前后轮失陷的工作情况。为考查底盘结构的整体性能,设计试验时,两个加载点分别位于驾驶室底部悬梁和发动机右侧悬梁上,试验装置如图 11-18 所示。试验载荷谱要求由产品研制方提出,为低频正弦波位移载荷。




图 11-18 底盘弯扭结合加载试验装置

底盘的测试原理如图 11-19 所示。应力测点分布如图 11-20 所示。测试系统如图 11-21 所示。






图 11-19 测试原理图




图 11-20 底盘应力测点分布图




图 11-21 测试系统图

### 11.6.3 加载控制结果

图 11-22 给出了正弦波载荷进行低周疲劳加载试验的控制曲线。图 11-23 给出了实测的底盘末端发动机右侧处 R1 点的弯、扭动态应变曲线。图 11-24 为右侧前轮处 R8 点的弯应变曲线。图 11-25 为左侧后轮处 L3 点的弯应变曲线。

由图可知,大型智能结构试验系统较好地实现了载荷波形的再现,控制系统控制品质优良,过渡过程曲线比较平滑,无超调,无振荡,加载控制精度达到 3% 以内。

另外,采用大型智能结构试验系统对底盘进行加载试验,不仅提高了试验精度,而且大大缩短了试验周期,降低了试验费用。






图 11-22 正弦波位移加载控制曲线



(a) 弯应变值曲线



(b) 扭应变值曲线

图 11-23 R1 点动态应变曲线




图 11-24 右侧前轮处 R8 点的弯应变曲线




图 11-25 左侧后轮处 L3 点的弯应变曲线

## 11.7 本章小结

本章根据大型电液伺服结构试验系统的特点及发展要求,利用神经网络在线学习模糊自适应控制策略,研制了智能伺服加载控制系统,开发了相应的软、硬件;采用多机并行工作方式和实时通讯手段,研制了计算机实时数据采集与分析系统,实现了结构试验控制与测试分析一体化。

实验和应用研究表明,神经网络智能伺服加载控制系统控制品质优良,有效克服了传统 PID 和自适应控制方法的缺陷,适应能力强,对系统的未知特性、不确定性和非线性均有很好的处理能力,实现了平稳、快速、高精度、无超调的控制目标。研制的大型智能电液伺服结构试验系统功能完善,智能程度较高,载荷谱设置方便,适用范围广,可满足各种不同试验规范的需要。系统设计中涉及了软、硬件设计方面的许多典型问题,不仅有利于推动我国结构试验领域的科技进步,对其他机电系统的控制研究亦具有通用性。

## 第十二章 结束语

### 12.1 一般性结论

神经网络控制是非线性控制的一个分支。它与传统非线性控制的区别在于神经网络控制是基于系统的输入-输出映射,而非系统的数学模型,控制器设计是通过学习来完成的,而不是针对模型进行的。可以说,神经网络控制器(NNC)是一种结构特殊的非线性控制器。它基本上不依赖于系统的数学模型,比较适合于那些具有不确定性和高度非线性的被控对象,并具有较强的适应和学习能力,因而神经网络控制又是智能控制的一个重要分支领域。迄今为止,有关神经网络结构和算法方面的文献大量见诸报道,应用研究也得到了迅速发展。在第一章中,我们对这些内容进行了归纳和总结,便于读者了解神经网络控制技术的发展历程和趋势。

神经网络控制方法所追求的目标是模拟人脑的控制行为。生理学研究发现,人脑的结构和功能实际上相当于一个高级控制器,不管控制任务多么复杂,如高难度的体操动作,人脑不需要被控对象和环境的数学模型,也无需求解任何微分方程,都可以通过人脑的控制行为来完成。生物神经控制系统这种对不确定性高度复杂问题的控制能力,是大多数传统控制方法所难达到的。

与人脑神经系统相比,目前提出的神经网络系统不论是网络模型、学习算法,还是网络规模,都极其原始、简单,其控制能力与上述控制目标相距甚远。如前所述,神经网络控制研究大多仍停留于数学仿真或实验室研究阶段,而极少用于实际系统的控制,甚至单纯利用神经网络控制方法的研究有停止不前的趋势。究其原因,除了一开始人们对神经网络控制寄予的期望过高外,还由于这一领域的发展远未达到成熟阶段,许多根本性的问题尚未得到解决。主要有:(1)神经网络的内部知识表达采用黑箱模型,初始权值的确定无法利用已有的系统信息,易陷于局部极小状态;(2)神经网络的泛化能力不足,制约了控制系统的鲁棒性和实用性;(3)神经网络本身的研究也有待突破,如发展专门适合于动态系统控制的神经网络模型;(4)硬件实现技术也有待突破,只有这样,神经网络大规模并行计算的潜力才能得到发挥。本书的重点内容就是探讨合适的网络模型、学习算法和控制结构,以期克服上述问题给神经网络控制方法的应用带来的困难。

在第二章中,我们讨论了控制系统设计中常用的几种神经网络模型及其学习方法,构造了复合输入动态递归神经网络模型,提出了增广 LPIDBP 学习算法和全局寻优自适应快速 BP 训练算法,较好的解决了网络模型的泛化能力和训练算法的全局收敛问题。第三章研究了非线性动态系统的神经网络辨识问题,提出了神经网络模型的在线自适应跟踪辨识方法,这种方法是利用神经网络在系统的期望轨迹附近跟踪学习系统的局部特性,从而做到对系统的实时跟踪逼近,网络规模可以选得较小而适应能力更强。

第四章至第七章提出了 4 种不同特色的神经网络控制结构。第四章针对模型未知的系统,提出一种神经网络并行自学习鲁棒自适应跟踪控制方法,并证明了构成的闭环控制

系统在其变量一致有界的意义上是全局稳定的;该方法通过引入运行监控器,解决了神经网络控制方法通常存在的实时性差的问题,实现了对复杂系统的在线学习控制。第五章从古典 PID 反馈控制思想出发,提出了具有 PID 结构形式的神经网络直接自适应控制策略;同时,为避免神经网络可能陷入局部极小,建立了一种混合神经网络直接自适应控制结构和相应的学习算法。第六章针对复杂系统神经网络控制前期控制品质欠佳的情况,基于反馈误差学习法,将模糊逻辑与神经网络控制相结合,设计了神经网络在线学习模糊自适应控制器,并证明了在一定条件下,这种控制器能保证闭环系统的稳定性。第七章从传递函数的角度出发,提出了基于神经网络辨识的在线迭代学习控制策略,并从理论上分析了迭代学习算法的收敛性。第四章和第六章的两种方法都是通过一个常规的反馈控制器来保证系统的稳定性,因此设计神经网络控制器时自由度较大,无需太多考虑系统的稳定问题,这样设计的控制系统就有可能具有良好的性能。从这里我们可以看出,如果将神经网络控制与传统控制思想有机结合起来,而不是非此即彼,是能够产生一些有效的方法的。特别是对工程界,既能发挥神经网络最重要的能够学习和适应的优点,又能在一定程度上解决神经网络控制中人们长期关注的稳定性问题。

我们将上述方法用于许多非线性系统以及未知不确定电液伺服系统的控制,仿真和实验结果均表明,这些方法均具有良好的控制性能。神经网络能跟踪学习系统的动力学特性,对系统的非线性和不确定性具有良好的处理能力。对电液伺服系统,能满足平稳、快速、高精度、无超调的控制要求。

第八章至第十一章从工程应用角度出发,研究设计了 4 种神经网络控制系统。

第八章将基于神经网络辨识的在线迭代学习控制和模型参考神经网络直接自适应控制方法用于非线性电液伺服板簧试验系统的控制,并基于范数空间稳定性理论,对板簧非线性系统进行了稳定性分析。

第九章将神经网络用于非对称缸弹性质量系统的控制,利用精确反馈线性化控制技术和神经网络不确定参数在线补偿控制的思想,针对电液伺服系统油液弹性模量的不确定性,提出了基于神经网络在线补偿的非线性控制方法,较好地克服了模型失配对系统性能产生的影响。

第十章将神经网络用于液压系统压力脉动主动控制中。针对液压系统压力脉动主动控制的特点和要求,设计了基于 B 样条神经网络的液压系统有源脉动控制系统,仿真和实验结果表明,神经网络方法能克服液压系统的不确定性和非线性的影响,具有良好的降脉效果。

第十一章将神经网络方法用于大型电液伺服结构试验系统的控制中。采用神经网络控制策略,研制了神经网络智能伺服加载控制系统,实现结构的低周疲劳加载控制和静力与协调加载控制,并做到了结构试验控制与测试分析一体化。实验和应用结果表明,神经网络智能控制系统适应能力强,对系统的未知特性、不确定性和非线性均有很好的处理能力,可满足不同试验规范的需要。

总之,由于神经网络控制是个具有争议性的领域,其发展仍处于未成熟阶段,许多根本性的问题尚待解决。本书针对各类非线性系统和电液伺服系统的控制需要,围绕如何在工程中实现神经网络在线辨识与控制以及如何保证神经网络控制系统的稳定性等问题,提出了一些行之有效的解决方法。这些工作离建立一套完善的神经网络控制理论与

系统设计方法还相差甚远,大量工作还有待今后进一步的研究。

## 12.2 未来的研究课题

在短短几年里,神经网络控制的研究从理论到应用都取得了许多可喜的进展,应该说是令人鼓舞的。但是我们也应该看到,由于受到技术发展的制约,人们对生物神经系统控制行为的研究和了解还相差甚远,对许多问题(有些还是重大的、根本性的问题)的认识还很不足,甚至是空白,目前采用的神经网络模型仅是对真实神经网络系统的极简单的模拟。另外,随着相关研究的日新月异,我们对事物已有的认识也会随着知识的更新换代而发生改变。因此很难对神经网络控制未来做一个准确的预测。

神经网络控制是非线性控制的一个分支,因此神经网络控制理论应视为非线性智能控制理论的一个分支,应与非线性控制理论并行发展,并随非线性理论本身的完善而不断完善。如前所述,仿真和工程应用都表明,神经网络控制器对处理工程中的非线性和不确定性问题是有效和有潜力的。但由于种种原因,神经网络在工程控制中的应用报道还比较少。因此未来神经网络控制研究应结合工程控制的需要,朝建立一套严格的神经网络控制理论和设计方法的方向发展。着重致力于以下几个方面:

### 1. 神经网络基础理论研究

神经网络经过长期大量的研究,在模型和算法等理论方面取得了许多成果,但与建立一套完整的理论体系还相差甚远。神经网络是一巨型非线性动力学系统,具有丰富的动力学复杂性。目前,人们对神经网络的认识和模拟还仅是其一些最简单的特征,许多复杂现象还有待进一步探索。从控制角度看,这部分内容应包括神经网络的统一模型与通用学习算法研究、网络结构选择(包括网络层数、单元数、激活函数的类型等)、神经网络的逼近精度以及与被逼近非线性映射之间的关系等。特别的,要研究专门适合于求解控制问题的动态神经网络模型,并能解决相应的动态神经网络的逼近能力和学习算法等问题。

由于动态神经网络本身就是一种动态时变系统,用于系统建模和控制时,不仅能反映系统动态的变化,而且无需预先确定系统的模型和阶次。因而近年来,人们更加重视具有内部反馈的动态网络在系统建模和控制中的应用,这也代表了神经网络建模和控制的发展方向。但是,目前对动态网络的研究远不如对静态网络研究的那么深入。一些文献只是针对某些结构,给出了相应的学习算法和仿真试验结果。对动态网络的模型、学习算法、以及应用动态神经网络进行系统建模、辨识和控制还需要进行系统深入的理论研究。

### 2. 神经网络控制器的稳定性分析

许多文献都对这一问题作过一定的研究。本书也针对提出的控制结构进行了分析和求证。但这些结论要么针对具体问题而言,要么有大量的附加条件,限制了神经网络控制器设计及其在工程中应用的灵活性。因此,需要研究更好的且具有一般意义的稳定性分析手段。

### 3. 神经网络控制器的鲁棒性分析

本书的研究结果和其他许多神经网络控制文献都表明,神经网络控制器在各种模型和各种工作条件下均具有良好的鲁棒性。然而,这些都是基于实验或仿真的结论,而非理论分析的结果。虽然在科学和工程界的许多领域中,对实验结果的研究分析是有可能建立某些新理论的;并且从控制器设计方法看,神经网络控制器不是基于模型而是基于系统的输入-输出数据通过学习来构造的,模型的精度对控制器的影响甚微。从这一点看,神经网络控制器可能确实具有鲁棒性。但部分传统控制论学者对此还持怀疑态度。而且,传统控制器的设计思想依然或多或少地影响着人们从事神经网络控制器的设计。因此,神经网络控制器的鲁棒性还有待进一步的理论分析。

### 4. 神经网络控制器的系统化设计方法研究

基于上述稳定性和鲁棒性分析,应建立一套神经网络控制器的系统化设计方法,并能结合非线性控制理论的新进展和工业系统发展的需要,进行新型神经网络控制器的分析与设计、以及相应的神经网络控制算法研究,特别是适合神经网络并行分布计算特点的快速学习算法。

### 5. 神经网络硬件实现研究

从理论上讲,与一般控制方法相比,神经网络控制系统具有良好的学习和适应能力、并行分布计算特点及多层信息处理能力等诸多潜在的优势。前者为神经网络在控制工程中的应用提供了重要的理论基础,从而引起了各个领域的学者和专家们的广泛兴趣;而后者更为工程界和企业界人士所关注。神经网络这些潜在的优势使人们相信,神经网络技术的发展将使包括电子科学和信息科学在内的许多科学产生革命性的变革,为控制科学的发展开辟新的途径。然而,这些潜在优势的发挥依赖于神经网络大规模实现技术的发展。目前,由于受到硬件实现技术的制约,神经网络大多通过计算机模拟实现。这使得现有的神经网络无论是规模还是学习算法都受到诸多限制。从而使相应的神经网络控制方法出现了许多暂时难以克服的困难。因此,神经网络只有做到硬件实现,其优势才能得到真正发挥。尤其在控制领域,对一些成熟的神经网络模型和学习算法,要研制相应的神经网络控制专用芯片。这是神经网络投入大规模应用不可或缺的重要环节。

### 6. 融合神经网络控制器的智能控制结构研究

本书第四章和第六章提出了两种融合神经网络控制器的混合控制结构,包括一个常规的反馈控制器和一个神经网络在线学习自适应控制器,二者是互补的,它们按一定的协作方式在系统控制中同时发挥作用。如果系统是确定的,且不存在噪声和干扰,神经网络的学习是完全的,那么反馈控制器的作用最终会变为零;如果系统存在噪声和干扰,反馈控制器的作用虽然不为零,但也仅作为一种补偿控制限制在很小的范围内。这种变结构学习适应控制方式既能有效利用系统有限的先验知识,节约系统资源,又能保证神经网络控制器在整个运行期间都能得到充分的训练,通过在线调整目标函数,增强系统的性能。实践证明,混合结构的控制性能比两个系统单独作用时要好。



我们知道,神经网络控制的过程实质上是根据系统的运行信息和某种优化原则,自动综合多变量函数映射的过程。这一过程是通过调整系统的结构和参数来实现的,其优点是不需要预先知道系统的确切参数,非常适合于时变不确定性特性。但学习过程通常较慢,且单纯神经网络方法也很难从理论上说明控制系统的稳定性和鲁棒性等问题。因此,若能将神经网络方法与系统的先验知识及有关启发信息结合起来,加以充分利用,则有可能产生更好的智能控制方法和结构。

事实上,早在 60 年代,有人就主张一个控制系统应有三个子系统组成<sup>[252]</sup>:一个先验的补偿控制器,即常规反馈控制环节,一个自适应环节和一个学习环节。

在进行控制系统设计时,如果被控对象或过程的先验信息是已知的且可以确定的描述,那么利用常规的各种控制方法就可以获得满意的性能;如果被控对象或过程存在时变特性,那么自适应环节可通过对输入-输出信息的在线观测,自动调整控制器参数,使系统保持最优或满意的工作状态。然而,当系统的先验知识未知或部分未知时,常规控制方法将失去意义。这时必须通过学习达到对未知信息的了解以至精确估计,进而采用优化控制方法得到满意的控制性能。工程实际中,以上三个环节常常是互相联系的,可通过某种协作方式构成一种变结构学习适应控制系统,这种变结构方式与传统变结构控制的区别在于:其中的各种控制作用不是相互独立的,而是通过某种规则有机地结合在一起,共同发挥作用。这类融合神经网络控制器的智能控制结构可以通过交互式学习来解决被控对象的不确定性问题,并能通过学习,在线优化控制系统的结构,从而改进系统的性能。这种方式可望有效利用系统的先验知识,而用较少的资源去解决较复杂的问题。但其工程实用性,特别是在这样一套智能控制理论的建立与发展方面还有待继续研究。如系统可调整部分的参数的稳定性和收敛性如何?如何以最优方式实现神经网络控制器与整个控制结构的融合,从而确保系统的稳定性,并使系统在变结构学习过程中做到运转平滑而无明显扰动?

## 参 考 文 献

- [1] 陈翰馥. 控制理论的现状及对它的期望. 信息与控制. Vol. 23 No. 1, 34—37, 1994
- [2] 高为炳, 霍伟. 控制理论的发展与现状——兼论复杂系统与智能控制. 93'国家教委自动控制学科组第二届第二次会议学术报告论文集. 西安. 1—6, 1993
- [3] A. Isidori, Nonlinear Control Systems: An Introduction, Springer, Verlag, 1989
- [4] 曾联銓. 李雅普诺夫直接法在自动控制中的应用. 上海科学技术出版社. 13—71, 1985
- [5] 汪德澍, 黄明瑞. 非线性控制系统引论. 成都电信工程学院出版社. 52—190, 1988
- [6] 高为炳. 非线性控制系统. 北京: 科学出版社, 1989
- [7] 斯洛廷, 李卫平. 应用非线性控制. 国防工业出版社, 1992
- [8] 卢强, 孙元章. 电力系统非线性控制. 北京: 科学出版社, 1—94, 1993
- [9] 陈予恕, 唐云. 非线性动力学中的现代分析方法. 北京: 科学出版社, 1992
- [10] 李人厚, 秦世引. 智能控制理论和方法. 西安交通大学出版社, 1994
- [11] 王顺显, 舒迪前. 智能控制系统及其应用. 机械工业出版社, 1995
- [12] 孙增圻, 张再兴, 邓志东. 智能控制理论与技术. 清华大学出版社, 1997
- [13] K. J. Austrom, Directions in Intelligent Control, ITAC'91, 15—17, 1991
- [14] 贺剑锋等. 模糊控制的新近发展. 控制理论与应用. Vol. 11, No. 2: 129—136, 1994
- [15] 张文修, 梁广锡. 模糊控制与系统. 西安交通大学出版社, 1994
- [16] 余永权, 曾碧. 单片机模糊逻辑控制. 北京航空航天大学出版社, 1995
- [17] 王立新. 自适应模糊系统与控制——设计与稳定性分析. 国防工业出版社, 1995
- [18] 焦李成. 神经网络的应用与实现. 西安电子科技大学出版社, 1993
- [19] W. W. McCulloch & W. Pitts, A logic calculus of the ideas imminent in neurons activity. Bulletin of Math. Bio., No. 5, 115—133, 1943
- [20] D. O. Hebb, The Organization of Behavior. Wiley, New York, 1949
- [21] F. Rosenblatt, Principles of Neurodynamics, New York, Spartan Book, 1962
- [22] B. Widrow & M. E. Hoff, Adaptive Switching Circuits, 1960 IRE WESCON Convention Record: Part 4, Computers: Man-Machine System, Los Angeles, 1960
- [23] M. L. Minsky & S. A. Papert, Perception. The MIT Press, Cambridge, MA, 1969
- [24] S. Grossberg, Some network that can learn, remember and reproduce any number of complicated spacetime pattern. Journal of Math. And Mach., Vol. 19, 53—91, 1969
- [25] T. Kohonen, Associative Memory: A System Theory Approach. Springer, New York, 1977
- [26] T. Kohonen, Self-Organization and Associative Memory. Springer, Berlin, 1984
- [27] J. Anderson & E. Rosenfeld, Neurocomputing. MIT Press, 1988
- [28] K. Fukushima, Recognition: a self-organizing neural network model for a mechanism of pattern recognition unaffected by shift position. Biol. Cyber, Vol. 36, No. 4, 193—220, 1980
- [29] K. Fukushima & S. Miyake, Recognition: a new algorithm for pattern recognition tolerant of deformation and shifts in position. Pattern Recognition, Vol. 15, No. 6, 455—469, 1982
- [30] K. Fukushima, Necognitron: A hierarchical neural network model of visual pattern recognition, Neural Networks, Vol. 1, No. 2, 1988
- [31] P. J. Werbos, Beyond regression: New tools for prediction and analysis in the behavior science. Ph. D. Thesis, Harvard University
- [32] B. Widrow, Adaline and Madaline, Proc. of 1st IEEE int. Conf. On Neural Networks, San Diego, USA, 145—

- [33] S. Amari et al., Mathematical theory on formation of category detecting nerve cell's. *Biol. Cybern.*, Vol. 29, 127—136, 1978
- [34] J.J. Hopfield, Neural networks and physical systems with emergent collective computational abilities. *Proc. Acad. Sci., USA*, Vol. 79, 2554—2558, 1982
- [35] J.J. Hopfield, Neurons with graded response have collective computational properties like those of two-state neurons. *Proc., Natl. Acad. Sci.*, Vol. 81, 3088—3092, 1984
- [36] J.J. Hopfield & D. W. Tank, Computing with neural circuits: A model. *Sci.* Vol. 233, 625—633, 1986
- [37] J.J. Hopfield & D. W. Tank, Neural computation of decisions optimization problem. *Biol. Cybern.*, Vol. 52, 141—152, 1985
- [38] J. A. Feldman & D. H. Ballard, Connectionist models and their properties. *Cognitive Science*, Vol. 6, 205—254, 1986
- [39] G. E. Hinton, T. J. Sejnowskii and D. H. Ackley, Boltzmann machine: constraint satisfaction networks that learn. CMV-CS-84-119, Carnegie-Mellon Uni., 1984
- [40] D. H. Ackley, G. E. Hinton & T. J. Sejnowskii, Learning algorithm for boltzmann machines. *Cognitive Science*, Vol. 9, 147—169, 1988
- [41] D. E. Rumelhart & J. L. McClelland, *Parallel Distributed Processing*, MIT Press, 1986
- [42] 焦李成著. 神经网络系统理论. 西安电子科技大学出版社, 1990
- [43] 焦李成编著. 神经网络计算. 西安电子科技大学出版社, 1993
- [44] 胡守仁主编. 神经网络应用技术. 国防科技大学出版社, 1993
- [45] P. G. J. Lisboa 著. 邢春颖等译. 现代神经网络应用. 电子工业出版社, 1996
- [46] D. T. Pham, Liu Xing, *Neural Networks for Identification, Prediction and Control*, Springer, Berlin, 1995
- [47] M. Omatu, Khalid and R. Yusof, *Neuro-Control and Its Applications*, Springer, Berlin, 1995
- [48] 丁国锋. 高阶神经网络控制理论及其在机电系统中的应用研究. 西安交通大学博士学位论文, 1997
- [49] V. Etxebarria, Adaptive Control of Discrete Systems Using Neural Networks, *IEEE Proc.-Control Theory Appl.*, Vol. 141, No. 4, 209—215, 1994
- [50] 吴耀军、陶宝祺, B样条小波神经网络, 模式识别与人工智能, Vol. 9, No. 3, 228—233, 1996
- [51] Liang Jin, P. N. Nikiforuk & M. M. Gupta, Adaptive Control of Discrete-time Nonlinear systems Using Recurrent Neural Networks, *IEEE Proc., Control Theory Appl.*, Vol. 141, No. 3, 169—176, 1994
- [52] K. P. Venugopal, A. S. Pandya & R. Sudhakar, A Recurrent Neural Network Controller and Learning Algorithm for The On-line Learning Control of Autonomous Underwater Vehicles, *Neural Networks*, Vol. 7, No. 5, 833—846, 1994
- [53] Liang Jin, P. N. Nikiforuk, M. M. Gupta, Dynamic Recurrent Neural Networks for Unknown Nonlinear Systems, *ASME Journal of Dynamic Systems, Measurement, and Control*, Vol. 116, No. 4, 567—576, 1994
- [54] C. Zhu, F. W. Paul, A Fourier Series Neural Network and Its Application to System Identification, *ASME Journal of Dynamic Systems, Measurement, and Control*, Vol. 117, No. 2, 253—261, 1995
- [55] P. F. Baldi, K. Hornik, Learning in Linear Neural Networks: A Survey, *IEEE Trans. on Neural Networks*, Vol. 6, No. 4, 837—857, 1995
- [56] K. J. Hunt, D. Sharbaro, R. Zbikowski & P. J. Gawthrop, Neural Networks for Control Systems—A Survey *Automatica*, Vol. 28, No. 6, pp. 1083—1112, 1992
- [57] W. T. Miller, R. S. Sutton & P. J. Werbos, *Neural Networks for Control*. MIT Press, Cambridge, 1990
- [58] B. Kosko, *Neural Networks and Fuzzy Systems*, Prentice Hall, Englewood, Cliffs, 1992
- [59] K. S. Narendra & K. Parthasarathy, Identification and Control for Dynamical Systems Using Neural Networks *IEEE Trans. Neural Networks*, Vol. 1, No. 1, 4—27, 1990
- [60] A. U. Levin & K. S. Narendra, Control of Nonlinear Dynamical Systems Using Neural Networks Part II: Observability, Identification and Control, *IEEE Trans. on Neural Networks*, Vol. 7, No. 11, 30—42, 1996

- [61] K. J. Hunt & D. Sbarbaro, Neural Networks for Nonlinear Internal Model Control, IEE Pro-D., Vol. 138, 431—438, 1991
- [62] 陈燕庆, 鹿浩. 神经网络理论及其在控制工程中的应用. 西北工业大学出版社, 1991
- [63] 王科俊, 王克成. 神经网络建模、预报与控制. 哈尔滨工程大学出版社, 1996
- [64] 周其节, 徐建闽. 神经网络控制系统的研究与展望. 控制理论与应用, Vol. 9, No. 6, 569—577, 1992
- [65] 何玉彬, 闫桂荣, 徐健学. 神经控制理论及应用的研究进展与展望. 现代科学技术研究的若干前言问题——现状与发展趋势. 西安交通大学出版社, 1996
- [66] A. U. Levin & K. S. Narendra, Control of Nonlinear Dynamical System Using Neural Networks: Controllability & Stabilization, IEEE Trans. Neural Networks, Vol. 4, No. 2, 1993
- [67] H. Wang, et al., Neural Networks Modelling of Unknown Nonlinear Systems Subject to Immeasurable Disturbances, IEE Proc.-Control Theory Application, Vol. 141, No. 4, 1994
- [68] K. Wang, et al., Robustness & Perturbation Analysis of A Class of Artificial Neural Networks, Neural Networks, Vol. 7, No. 2, 1994
- [69] J. R. Rao, Neural Network Based Parameter Estimation of Unstable Aerospace Dynamic Systems, IEE Proc.-Control Theory Appl., Vol. 141, No. 6, 385—388, 1994
- [70] K. S. Narendra and S. Mukhopadhyay, Adaptive Control of Nonlinear Multivariable Systems Using Neural Networks, Neural Networks, Vol. 7, No. 5, 737—752, 1994
- [71] G. Lightbody & G. W. Irwin, Direct Neural Model Reference Adaptive Control, IEE Pro-D., Vol. 142, No. 1, 31—43, 1995
- [72] D. Andreas, E. Sebastian & R. Horst, Model Predictive Control Using Neural Networks, IEEE Contr. Syst. Mag., Vol. 15, No. 5, 61—66, 1995
- [73] Z. Yao, S. Pratyush & E. H. Grant, An on-line Trained Adaptive Neural Controller, IEEE Contr. Syst. Mag., Vol. 15, No. 5, 67—75, 1995
- [74] Iwata, J. Ghosh and Y. Shin, Time Optimal Control Using PI-Sigma Network, IEEE Proc. on Neural Networks, Vol. 1, 546—551, 1993
- [75] 王耀南. 基于神经网络的非线性最优控制. 湖南大学学报, Vol. 22, No. 5, 68—74, 1995
- [76] 刘廷章. 回转类复杂曲面加工精度的自适应与智能控制策略研究, 西安交通大学博士学位论文, 1996
- [77] 李新忠, 简林柯, 何钺. 基于神经网络的优化控制. 机械工业自动化. Vol. 19, No. 2, 24—26, 1997
- [78] 阮晓钢. 非线性逆神经解耦飞行控制方法. 航空学报, Vol. 18, No. 1, 1997
- [79] 胡泽新. 神经网络自适应控制系统研究. 控制与决策. Vol. 7, No. 5, 361—366, 1995
- [80] Hoskins, J. N. Hwang and J. Vagners, Iterative Inversion of Neural Networks and Its Application to Adaptive Control, IEEE Trans. on Neural Networks, Vol. 3, No. 2, 292—301, 1992
- [81] 李新忠, 简林柯, 何钺. 非线性系统的模型参考神经网络控制. 信息与控制. Vol. 25, No. 6, 367—372, 1996
- [82] 刘小柯, 崔杜武. 一类非线性系统神经内模控制的若干定性性质. Proceedings of The Second Chinese World Congress on Intelligent Control and Intelligent Automation, Xi'an, 2112—2114, June 1997
- [83] 李士勇. 模糊控制、神经网络控制和智能控制. 哈尔滨工业大学出版社, 1996
- [84] S. I. Mistry, S. S. Nair, Identification and Control Experiments Using Neural Designs, IEEE Control Systems, Vol. , No. , 48—57, 1994
- [85] W. A. Porter, W. Liu, Neural Controllers for Systems With Unknown Dynamics, IEEE Trans. on Aerospace and Electronic Systems, Vol. 31, No. 4, 1331—1340, 1994
- [86] 孙富春, 孙增圻, 张戎军. 机械手的神经网络直接离散时间自适应控制算法. 清华大学学报(自然科学版). Vol. 37, No. 4, 101—105, 1997
- [87] D. R. Seidl, S. L. Lam, Neural Network Compensation of Gear Backlash Hysteresis in Position-Controlled Mechanisms, IEEE Trans. on Industry Appl., Vol. 31, No. 6, 1475—1483, 1995
- [88] S. D. Snyder and N. Tanaka, Active Control of Vibration Using a Neural Network, IEEE Trans. on Neural Networks, Vol. 6, No. 4, 819—828, 1995

- [89] 何玉彬. 神经网络控制与大型智能电液伺服结构试验系统研究. 西安交通大学博士学位论文, 1999
- [90] 司徒, 周贵安等. 基于梯度监督学习的理论与应用(1)——基本算法, 清华大学学报(自然科学版). Vol. 37. No. 7. 71—73, 1997
- [91] 司徒, 周贵安等. 基于梯度监督学习的理论与应用(2)——训练机制, 清华大学学报(自然科学版). Vol. 37. No. 9. 104—107, 1997
- [92] Prokhorov, R. A. Santiago and D. C. Wunsch, Adaptive Critic Designs : A Case Study for Neurocontrol, Neural Networks , Vol. 8, No. 9, 1367—1372, 1995
- [93] Clemens, Stable Nonlinear Observer Design With Neural Network, IFAC Proc. on Motion Control , 567—574, 1995
- [94] Alessandro, Intelligent Neural Network Controller for a Position System, IFAC Proc. on Motion Control , 189—198, 1995
- [95] Riko, Neural network Robot Control Applications, IFAC Proc. on Motion Control , 559—566, 1995
- [96] 盛万兴. 模糊控制优化设计研究及其在电液伺服系统中的应用. 西安交通大学博士学位论文, 1995
- [97] S. C. Lee & E. T. Lee, Fuzzy Sets and Neural Networks, J. Cybernetics, No. 4, 83—103, 1974
- [98] S. C. Lee & E. T. Lee, Fuzzy Neural Networks, Math. Biosci. , Vol. 23, 151—177, 1975
- [99] Wang Li-Xin, Fuzzy Systems are Universal Approximators, IEEE Fuzzy'92, 1163—1170, 1992
- [100] H. Takagi, Fusion Technology of Fuzzy Theory and Neural Networks-Survey and Future Directions, Proc. of Int. Conf. On Fuzzy Logic and Neural Networks, Iizuka, Japan, 13—26, 1990
- [101] Horikawa et al. , On Fuzzy Modeling Using Neural Networks With BP Algorithm, IEEE Trans. Neural Networks, Vol. 3, No. 5, 801—806, 1992
- [102] C. T. Lin, et al. , Neural Networks Based Fuzzy Logic Control and Design System, IEEE Trans. on Computer, Vol. 40, No. 12, 1320—1336, 1991
- [103] J. R. Jang, Self-Learning Fuzzy Controller Based on Temp Back Propagation, IEEE Trans. on Neural Networks, Vol. 3, No. 5, 714—723, 1992
- [104] 应行仁, 曾南. 采用 BP 神经网络记忆模糊规则的控制. 自动化学报. Vol. 17. No. 1. 63—67, 1991
- [105] H. R. Bernji, et al. , Learning and Turning Fuzzy Logic Controllers Through Reinforcements, IEEE Trans. Neural Networks, Vol. 3, No. 5, 724—740, 1992
- [106] S.B. Chen & L. Wu, Self-learning Fuzzy Neural Networks for Control of The Arc Welding Process, Proceedings of The 2nd Chinese World Congress on Intelligent Control and Intelligent Automation, Xi'an, China, 1358—1363, 1997
- [107] W.X. Shi, How to solve the uncertainty problems in hydraulic servo system, Proceedings of 95 ICFP, Shanghai, China, 1—6, 1995
- [108] 陆元章. 液压系统的建模与分析. 上海交通大学出版社, 1989
- [109] 汤清明. 高精度超低频电液伺服柱塞缸金属疲劳试验系统. 西安交通大学硕士学位论文, 1989
- [110] I.D. 朗道著. 吴百凡译. 自适应控制——模型参考方法. 国防工业出版社, 1985
- [111] C.J. 哈里斯等编. 李清泉译. 自校正和自适应控制——理论与应用. 科学出版社, 1986
- [112] 刘白雁. 模型跟随自适应控制理论的研究及其应用. 西安交通大学博士学位论文, 1990
- [113] 丁崇生, 刘白雁, 史维祥. 模型跟随自适应控制新方法的理论研究及工程应用. 西安交通大学学报. No. 4, 1990
- [114] 丁崇生, 何晓佳, 王大庆等. 高精度高响应电液伺服系统自适应控制的工程实现. 机床与液压. No. 2. 72—77, 1995
- [115] Y. F. Xiong, S. LeQuoc & R. M. H. Cheng, Adaptive Control of A Synchronizing Servo-system, Proceedings of International Off-Highway and Powerplant Congress and Exposition, Milwaukee, WI, USA, 1992
- [116] M.C. Shih & Y.R. Sheu, Adaptive Position Control of An Electro Hydraulic Servo Cylinder. Vibration, Control Engineering, Engineering for Industry, Vol. 34, No. 3, 370—376, 1991
- [117] 何晓佳. 电液伺服板簧试验机控制策略的研究. 西安交通大学硕士学位论文, 1992

- [118] 陈以平. 电液伺服板簧试验机的模型参考自适应控制, 浙江大学硕士学位论文, 1988
- [119] 闫桂荣, 田晓耕, 张改慧. 采用 MRAC 的气-液联合多通道协调加载控制系统研究. 应用力学学报. Vol. 12. No. 4. 39—46, 1995
- [120] A. Luo, H. Hun, Intelligent Control for Electro-hydraulic Proportional Position Servo System, Proceedings of the 4th International Conference on Fluid Power Transmission and Control. Hangzhou, China, 1997:246—250
- [121] Y. Jen & C. Lee, Robust Speed Control of A Pump Controlled Motor System, IEE Proceeding-D, Vol. 139, No. 6, 503—510, 1992
- [122] H. Zhang, P. N. Nikiforuk & P. R. Ukrainetz, A Neural Network Approach for MIMO Electro-hydraulic Servosystem Control, Proceedings of the 3rd International Conference on Fluid Power Transmission and Control. Shanghai, China, 1995
- [123] 王孙安, 林廷圻, 史维祥. 液压伺服控制的新发展. 机床与液压. No. 1. 8—14, 1991
- [124] 沙道航. 大型钢坯修磨机恒力加载系统跟随特性的研究. 西安交通大学博士学位论文, 1994
- [125] P. M. FitzSimons, J. J. Palazzolo, Part 1: Modeling of A One-Degree-of-Freedom Active Hydraulic Mount, ASME Journal of Dynamic Systems, Measurement, and Control, Vol. 118, No. 3, 439—442, 1996
- [126] P. M. FitzSimons, J. J. Palazzolo, Part 2: Control of A One-Degree-of-Freedom Active Hydraulic Mount, ASME Journal of Dynamic Systems, Measurement, and Control, Vol. 118, No. 3, 443—448, 1996
- [127] A. R. Plummer, N. D. Vaughan, Robust Adaptive Control for Hydraulic Servosystems, ASME Journal of Dynamic Systems, Measurement, and Control, Vol. 118, No. 2, 237—244, 1996
- [128] J. E. Bobrow, K. Lum, Adaptive High Bandwidth Control of A Hydraulic Actuator, ASME Journal of Dynamic Systems, Measurement, and Control, Vol. 118, No. 4, 714—720, 1996
- [129] 李运华. 近代电液伺服系统中某些非线性控制问题的研究. 西安交通大学博士学位论文, 1994
- [130] Schneider, Martin, Nonlinear Motion Control of Hydraulically Driven Large Redundant Manipulators, IFAC Proc. on Motion Control, 269—278, 1995
- [131] D. H. Sha, H. Y. Yang, J. M. Zhang, Research on Discrete Robust Variable Structure Control of Hydraulic Elevator Velocity System, Proceedings of the 4th International Conference on Fluid Power Transmission and Control. Hangzhou, China, 275—278, 1997
- [132] T. L. Chern & Y. C. Wu, Design of Integral Variable Structure Controller and Application to Electro-hydraulic Velocity Servo-system, IEE Proceedings-D, Vol. 138, No. 5, 439—444, 1991
- [133] W. M. Huang, Y. Yang, & G. F. Xiong, Adaptive Fuzzy Neural Network Control in Hydraulic Servo System, Proceedings of the 4th International Conference on Fluid Power Transmission and Control. Hangzhou, China, 189—193, 1997
- [134] W. X. Sheng, R. W. Dai, S. A. Wang & W. X. Shi, Electro-hydraulic Servo Control Based on Neuro-Fuzzy Technique, Proceedings of the 4th International Conference on Fluid Power Transmission and Control. Hangzhou, China, 232—236, 1997
- [135] 王孙安. 大功率液压马达速度伺服系统的控制方法研究. 西安交通大学博士学位论文, 1989
- [136] 刘艳秋. 参数自校正 Fuzzy-PI 控制器及其在电液伺服结构试验系统中的应用. 西安交通大学硕士学位论文, 1997
- [137] 汤志勇. 神经网络变结构控制及其在电液伺服系统中应用的研究. 西安交通大学博士学位论文, 1997
- [138] J. S. Albus, A new approach to manipulator control: Cerebellar Model Articulation Controller (CMAC). IEEE Trans. ASME, No. 9, 1975
- [139] W. T. Miller, Sensor based control of robotics manipulators using a general learning algorithm. IEEE Trans. On Robotics and Automation, No. 3, 1987
- [140] G. A. Larsen, S. Cetinkunt & A. Dornetz, CMAC neural network control for high precision motion control in the presence of large friction. Journal of Dynamics System, Measurement and Control, No. 9, 1995
- [141] A. Wiedand & R. Leighton, Geometric Analysis of Neural Network Capacity, Proc. IEEE First ICNN, 385—392, 1987

- [142] G. Cybenko, Approximation by Superpositions of A Sigmoidan Function, Math. Contr. Signal Sys., Vol. 2, No. 4, 303—314, 1989
- [143] K. I. Funahashi, On The Approximate Realization of Continuous Mapping by Neural Networks, Intel. Conf. NN, 1989
- [144] K. Hornik, Approximation Capabilities of Multilayer Feedforward Network, Neural Networks, Vol. 4, No. 2, 251—257, 1991
- [145] T. Chen & H. Chen, Approximation to Nonlinear Continuous Functionals by Neural Networks With Application to Dynamic System, IEEE Trans. NN, Vol. 4, No. 3, 910—918, 1993
- [146] K. Hornik, Some New Results on Neural Network Approximation, Neural Networks, Vol. 6, 1069—1072, 1993
- [147] K. Hornik, M. Stinchcombe & H. White, Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks. Neural Networks, No. 3, 551—560, 1990
- [148] W.D. Hu & Z.Z. Wang, The approximation of arbitrary functions with multilayer BP neural networks. Proc. I-JCNN'92, Beijing, China, 1992
- [149] A.G. Parlos, B. Fernandez, A.F. Atiyaz & W.K. Tsai, An accelerated Learning Algorithm for Multilayer Perception Networks, IEEE Trans. on NN, Vol. 5, No. 3, 493—497, 1994
- [150] 杨大力, 刘泽民. 多层前向神经网络中 BP 算法的误差分析及改进的算法. 电子学报. Vol. 23. No. 1. 117—120, 1995
- [151] 王科俊, 金鸿章, 战兴群. 不同 S 形函数对 BP 算法影响的理论及实验研究. 自动化理论、技术与应用——中国自动化学会第十届青年学术年会论文集. 西安: 西北工业大学出版社, 299—303, 1994
- [152] 邓志东, 孙增圻. 利用线性再励的自适应变步长快速 BP 算法. 模式识别与人工智能. Vol. 6. No. 4. 319—323, 1993
- [153] Q. Hong & H. Zhenya, Variable Step BP Algorithm Which Prunes Away Redundant Connections Dynamically, I-JCNN, No. 2, 441—445, Beijing, 1992
- [154] V. V. Phansalkar & P. S. Sastry, Analysis of The Back-Propagation Algorithm With Momentum, IEEE Trans. on NN, Vol. 5, No. 3, 505—506, 1994
- [155] S. Roy & J. J. Shynk, Analysis of The Momentum LMS Algorithm, IEEE ISCAS, USA, 1992
- [156] R. Vitthal, P. Sunthar & CH. D. Rao, The Generalized Proportional-Integral-Derivative(PID) Gradient Descent Back Propagation Algorithm, Neural Networks, Vol. 8, No. 4, 1995
- [157] 邓志东, 孙增圻, 刘建伟. BP 网络的 PID 型二阶快速学习算法. 自动化学报. Vol. 21. No. 1. 67—73, 1995
- [158] 孙增圻. 计算机控制理论及应用. 清华大学出版社. 25—54, 1989
- [159] 李新忠. 电液伺服系统的神经网络非线性控制. 西安交通大学博士学位论文, 1998
- [160] K. P. Venugopal & A. S. Pandya, Aloplex Algorithm for Training Multilayer Neural Networks, IEEE Int. J. Conf. on NN, 196—201, 1991
- [161] D. J. Montana & L. Davis, Training Feedforward Network Using Genetic Algorithm, Int. J. Conf. on AI, 762—767, 1989
- [162] M. R. Azimi-Sadjadi & R. J. Lion, Fast Learning Process of Multilayer Neural Networks Using Recursive Least Squares Method, IEEE Trans. on SP, Vol. 40, No. 3, 446—450, 1992
- [163] 谭永红. 多层前向神经网络的 RLS 训练算法及其在辨识中的应用. 控制理论与应用. Vol. 11. No. 5. 594—599, 1994
- [164] M. Zak, Terminal Attractors For Addressable Memory in Neural Networks, Physics Letters A, Vol. 133, No. 1, 2, 18—22, 1988
- [165] M. Zak, Terminal Attractors in Neural Networks, Neural Networks, Vol. 2, 259—274, 1989
- [166] N. Bhat & T. J. McAvoy, Use of Neural Nets for Dynamic Modeling and Control of Chemical Process System, Computer & Cham. Eng., Vol. 14, No. 5, 573—583, 1990
- [167] S. Chen, S. Billings & P. M. Grant, Nonlinear System Identification Using Neural Networks, Int. J. Control, Vol. 151, No. 6, 1191—1214, 1990

- [168] 刘延年,冯纯伯. 用神经网络进行非线性离散动态系统辨识的可行性. 控制理论与应用. Vol. 11. No. 4. 413—419, 1994
- [169] 潘巨辉. 非线性系统辨识及其仿真研究——应用神经网络方法. 计算机仿真. No. 2. 32—38, 1993
- [170] Y. B. He, G. R. Yan & J. X. Xu, Real-time Adaptive Predictive Control Using Neural Networks, Proceedings of The Second Chinese World Congress on Intelligent Control and Intelligent Automation, Xi'an, June 1997, 1978—1983
- [171] 何玉彬,盛玮,闫桂荣,徐健学. 电液伺服结构试验机的神经网络鲁棒自适应跟踪系统. 二炮工程学院学报. No. 1, 1998
- [172] T. A. Johansen & B. A. Foss, Representing and learning unmodelled dynamics with neural network memories. Proc. Amer. Control Conf., Chicago, 3037—3043, 1992
- [173] M. A. Kramer et al, Embedding theoretical models in neural networks. Proc. Amer. Control Conf., Chicago, 475—479, 1992
- [174] P. J. Antsaklis, Ed., Special Issue on Neural Networks in Control System, IEEE Contr. Syst. Mag., Vol. 10, No. 3, 1990
- [175] L. Jin, P. N. Nikiforuk & M. M. Gupta, Direct Adaptive Output Tracking Control Using Multilayered Neural Networks, IEE Pro-D., Vol. 140, No. 6, 393—398, 1993
- [176] Y. H. Tan, An Architecture for Adaptive Neural Control, Journal A, Vol. 34, No. 4, 12—16, 1993
- [177] F. C. Chen & H. Khalil, Adaptive Control of Nonlinear Systems Using Neural Networks, Int. J. Control, Vol. 55, No. 6, 1299—1317, 1992
- [178] Y. M. Park, M. S. Choi & K. Y. Lee, An Optimal Neuro-Controller for Nonlinear Dynamic System, IEEE Trans. On NN, Vol. 7, No. 5, 1099—1110, 1996
- [179] C. W. Anderson, Learning to Control an Inverted Pendulum Using Neural Networks, IEEE Contr. Syst. Mag., Vol. 9, No. 3, 31—37, 1989
- [180] 王耀南. 人工神经网络在伺服最优鲁棒控制中的应用, 控制与决策, Vol. 12, No. 1, 14—19, 1997
- [181] 任庆昌, 张永辉. 具有非线性特性电加热炉的神经网络内模控制. Proceedings of The 2nd Chinese World Congress on Intelligent Control and Intelligent Automation. Xi'an. China. 782—785, 1997
- [182] 何玉彬, 闫桂荣, 徐健学. 不确定非线性系统的神经网络在线自学习控制, 现代力学与科技进步——中国力学学会成立 40 周年学术大会论文集. 北京: 清华大学出版社. 786—789, 1997
- [183] 何玉彬, 张智栋, 闫桂荣, 徐健学. 电液力伺服系统的神经网络自适应预测 PI 控制. 航空动力学报. No. 4, 1997
- [184] Y. B. He, J. Y. Sun & M. G. Xue et al, Neural Network Adaptive Predictive Controller for Electro-hydraulic Servo Structural Testing System, 2nd International Symposium on Test and Measurement, Beijing, June, 294—297, 1997
- [185] Y. B. He, H. Zhao, Y. Zhu & W. Sheng, Neural Network Self-Learning Variable-Robustness Adaptive Tracking Control for Electro-hydraulic Servo System, 3rd International Symposium on Test and Measurement, Xi'an, June 1999
- [186] 何玉彬, 闫桂荣, 徐健学. 电液伺服结构试验系统的神经网络快速鲁棒跟踪控制. 控制理论与应用. No. 5, 1999
- [187] T. H. Eli & F. A. Frank, A Stability Based Neural Network Control Method for A Class of Nonlinear System, IEEE Int. Conf. On NN, 1047—1052, 1991
- [188] F. C. Sun & Z. Q. Sun, Stable Discrete-time Neural Control for Robot Manipulators, Proceedings of The 2nd Chinese World Congress on Intelligent Control and Intelligent Automation, Xi'an, China, 981—986, 1997
- [189] H. L. Pei, Q. J. Zhou & T. P. Leung, On Learning Convergence of A Kind of Real-time Neural Network Nonlinear Control System, 控制理论与应用, 1996
- [190] B. D. O. Anderson & R. M. Johnstone, Adaptive System and Time-Varying Plants, Int. J. Control, Vol. 37, 367—377, 1983



- [191] R. P. Lippmann, An Introduction to Computing With Neural Nets, IEEE Acoustics, Speech and Signal Processing Magazine, 4—22, 1987
- [192] 何玉彬,刘艳秋,闫桂荣,徐健学. 结构试验机的神经网络内模自适应跟踪控制系统. 应用力学学报. Vol. 15. No. 3. 1—6, 1998
- [193] M. Yuan, A. N. Poo & G. S. Hong, Direct Neural Control System: Nonlinear Extension of Adaptive Control, IEE Proc-Control Theory Appl. Vol. 142, No. 6, 661—667, 1995
- [194] 何玉彬,闫桂荣,张道立,徐健学. 电液伺服结构加载系统的神经网络直接自适应输出跟踪控制. 机床与液压. No. 2, 1997
- [195] Q. H. Dai, Y. D. Li, W. Wei & T. Y. Chai, Robust Direct Adaptive Control Based on Dynamic Neural Networks, Proceedings of The 2nd Chinese World Congress on Intelligent Control and Intelligent Automation, Xi'an, China, 976—980, 1997
- [196] 韩京清. 处理非线性控制系统的直接方法. 控制理论及其应用年会论文集. 553—559, 1992
- [197] H. Gomi & M. Kawato, Neural Network Control for A Closed-Loop System Using Feedback-Error-Learning, Neural Networks, Vol. 6, 933—946, 1993
- [198] 吕柏权,李天铎. 一种具有全局最优的神经网络 BP 算法. 清华大学学报(自然科学版). Vol. 37. No. 2. 32—34, 1997
- [199] M. Kawato, K. Furukawa & R. Suzuki, A Hierarchical Neural Network Model for Control and Learning of Voluntary Movement, Biological Cybernetics, Vol. 57, 169—185, 1987
- [200] M. Kawato et al, A Hierarchical Model for Voluntary Movement and Its Application to Robotics, IEEE Control System Magazine, No. 4, 8—17, 1988
- [201] H. Miyamoto, M. Kawato et al, Feedback-error-learning Neural Network for Trajectory Control of A Robotic Manipulator, Neural Networks, No. 1, 251—265, 1988
- [202] R. T. Newton & Y. S. Xu, Neural Network Control of A Space Manipulator, IEEE Control System Magazine, No. 6, 14—22, 1993
- [203] H. Ohno, T. Suzuki, K. Aoki, & A. Takahasi et al, Neural Network Control for Automatic Braking Control System, Neural Networks, Vol. 7, No. 8, 1303—1312, 1994
- [204] 何玉彬,刘艳秋,徐立勤等. 电液伺服系统的神经网络在线自学习自适应控制. 中国电机工程学报. Vol. 18. No. 6. 434—437, 1998
- [205] 何玉彬,王晓予,闫桂荣等. 神经网络在线自学习模糊自适应控制及其应用. 中国电机工程学报
- [206] J. G. Kuschewski, S. Hui, Application of Feedforward Neural Networks to Dynamical System Identification and Control, IEEE Trans. on Control Systems Technology, Vol. 1, No. 1, 37—49, 1993
- [207] Arimoto, Bettering Operation of Dynamical Systems by Learning : A New Control Theory for Servomechanics Systems, Proc. 23th IEEE Conf. on Decis. and Control, 1064—1069, 1984
- [208] 曾南,应行仁. 非线性系统迭代学习算法. 自动化学报. Vol. 18. No. 2. 168—176, 1992
- [209] Moore, M. Dahleh and S. P. Bhattacharyya, Iterative Learning Control: A Survey and New Results, Journal of Robotic Systems, Vol. 9, No. 5, 878—892, 1992
- [210] 李新忠,简林柯,何钺. 迭代学习控制的研究与应用. 机床与液压. Vol. 25. No. 6. 3—5, 1997
- [211] 林辉,戴冠中. 一类非线性系统的学习控制算法. 西北工业大学学报. Vol. 11. No. 4. 397—402, 1993
- [212] Bien, K. M. Huh, Higher-Order Iterative Learning Control Algorithm, IEEE Proceedings, Vol. 136, Pt. D, No. 3, 105—112, 1989
- [213] 刘连中,汪一彭,张启先. 机器人运动的学习控制. 北京航空航天大学学报. No. 3. 10—16, 1993
- [214] 李新忠,简林柯,何钺. 基于性能指标的非线性系统迭代学习控制. 机床与液压. Vol. 24. No. 6. 9—10, 1996
- [215] 王大庆. 高精度中凸变椭圆活塞加工系统的研究. 西安交通大学博士学位论文, 1997
- [216] 秦志敏,潘宇臣. 渐变刚度钢板弹簧的设计计算. 汽车工程. Vol. 16. No. 4. 219—224, 1994
- [217] 张立军,何辉. 钢板弹簧新的计算方法及其在设计中的应用. 汽车工程. Vol. 16. No. 1. 50—57, 1994

- [218] 周继铭,程悦荪. 板簧动态特性的研究. 汽车工程. Vol.14. No.1. 60—64,1992
- [219] 黄琳. 稳定性理论. 北京大学出版社,1992
- [220] 徐成贤,徐宗本. 矩阵分析. 西北工业大学出版社,1991
- [221] Soderlind G. On Nonlinear Difference and Differential Equation. BIT, Vol 24, 667—680, 1984
- [222] 项国波著. ITAE 最佳控制. 机械工业出版社,1986
- [223] G. Vossoughi, M. Donath, Dynamic Feedback Linearization for Electrohydraulically Actuated Control Systems, ASME Journal of Dynamic Systems, Measurement, and Control, Vol. 117, No. 3, 468—477, 1995
- [224] 黄涓,吴白羽. 叶片泵高压化中的低噪声问题研究. 液压工业. No.1,1986
- [225] Na Chenglie, Xing Keli, Low noise valve plate of axial piston pump. Proc. of 2nd Int. Symposium on Fluid Power Transmission and Control, Shanghai, China, 1994
- [226] A. Garbaciak, J. S. Stecki, Pressure pulsation damping in hydraulic systems. Proc. of 2nd Int. Symposium on Fluid Power Transmission and Control, Shanghai, China, 1994
- [227] 陈克安,马远良. 自适应有源噪声控制——原理、算法及实现. 西北工业大学出版社,1993
- [228] 任廷荣. 空调通风管道内低噪声自适应有源控制研究. 西安交通大学博士学位论文,1995
- [229] C. F. Ross, An adaptive digital filter for broadband active sound control, Journal of Sound & Vib., 80,1982
- [230] S. D. Snyder, C. H. Hansen, Active noise control in ducts: some physical insight, Journal of Acoust. Soc. Am. 86, 1989
- [231] 沙家正. 管道有源消声器. 声学学报, No. 7, 1982
- [232] 朱海朝,黄映云. 自适应管道有源降噪研究. 噪声与振动控制. No. 4, 1993
- [233] 陈克安,马远良. 具有多层前馈神经网络结构的自适应有源消声系统. 第四届全国信号处理学术会议论文集, 1992
- [234] Fan Jang, Adaptation for active noise control. IEEE Control System, No. 12, 1997
- [235] 刑科礼. 液压系统压力脉动的衰减理论与方法研究, 西安交通大学博士学位论文, 1998
- [236] 沙家正,孙广荣. 有源消声器消声机理的研究. 声学学报. No. 2, 1983
- [237] 田静. 关于单极子次声源管道降噪能量机理的理论分析. 声学学报. No. 5, 1992
- [238] 苏尔皇. 常规蓄能器消减液压系统压力脉动研究及新型广谱消减器探索. 国际流体动力及控制会议论文集. 杭州, 1995
- [239] S. D. Snyder, Active control of vibration using a neural network. IEEE Trans. On Neural Networks, Vol. 6, No. 4, 819—828, 1995
- [240] N. E. Hubing, S. T. Alexander, Statistical analysis of initialization methods for RLS adaptive filters, IEEE Trans. On Signal Processing, No. 10, 1991
- [241] 李兵. 高响应电液伺服系统动态特性的研究与控制分析, 西安交通大学硕士学位论文, 1991
- [242] 何玉彬,程卫国,同桂荣,徐健学. 电液伺服协调加载系统的神经网络自学习 PSD 控制. 机床与液压. No. 2. 3—5, 1998
- [243] Yubin He, Guirong Yan & Jianxue Xu et al, Neural Network Online Self-learning Tracking Control for Electro-hydraulic Servo Fatigue Testing System, 4th International Conference on Flow Power Transmission and Control, Hangzhou, Zhejiang, 255—259, 1997
- [244] Y. B. He, J. Y. Sun, Y. Q. Liu & G. R. Yan, Computer-aided Data Acquisition and Analysis for Electro-hydraulic Servo Structural Testing System, 2nd International Symposium on Test and Measurement, Beijing, 228—231, 1997
- [245] He Yubin, Wang Xiaoyu & Yan Guirong, A Large Scale Intelligent Electro-hydraulic Servo Structural Test System. International Symposium on Theory and Application of Structural Engineering Test Method. Beijing, 1999
- [246] 同桂荣,何玉彬,胡剑峰等. 机械结构组合波形疲劳加载控制方法研究报告. 西安交通大学机械结构强度与振动国家重点实验室, 1996 年
- [247] 李孔语等. 卧式双缸同步加载系统控制策略研究, 机床与液压, No. 2, 88—91, 1994
- [248] 孙丽萍. 计算机控制结构试验系统软件研制——一台计算机控制多个独立的加载试验, 测控技术. Vol. 13. No. 6,

1994

- [249] 刘白雁,丁崇生,史维祥等. 高精度多通道电液同步加载系统. 机床与液压
- [250] 徐安洲. 液压同步加载操纵台. 同济大学. 成果编号:87203564
- [251] 刘杰,马中武. 多通道协调加载控制系统设计. 测控技术. Vol.15. No.4, 1996
- [252] J. Sklansky, Learning Systems for Automatic Control. IEEE Trans. Automatic Control, 1996